



TUGAS AKHIR - SS 145561

**PERAMALAN JUMLAH PENERIMAAN MASA
PPh Pasal 21 DI KANTOR PELAYANAN
PAJAK PRATAMA SURABAYA GUBENG**

Pratiwi Penta Atrivi
NRP 1314 030 009

Dosen Pembimbing
Dra. Lucia Aridinanti, M.T

DEPARTEMEN STATISTIKA BISNIS
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya 2017



TUGAS AKHIR - SS 145561

**PERAMALAN JUMLAH PENERIMAAN MASA PPh PASAL
21 DI KANTOR PELAYANAN PAJAK PRATAMA
SURABAYA GUBENG**

Pratiwi Penta Atrivi

NRP 1314 030 009

Dosen Pembimbing

Dra. Lucia Aridinanti, MT

DEPARTEMEN STATISTIKA BISNIS

Fakultas Vokasi

Institut Teknologi Sepuluh Nopember

Surabaya 2017



FINAL PROJECT - SS 145561

**FORECASTING AMOUNT OF TAX REVENUES ARTICLE
21 IN THE TAX SERVICE OFFICE PRATAMA
SURABAYA GUBENG**

Pratiwi Penta Atrivi

NRP 1314 030 009

Supervisor

Dra. Lucia Aridinanti, M.T

DEPARTEMENT OF BUSINESS STATISTICS

Faculty Of Vocational

Institut Teknologi Sepuluh Nopember

Surabaya 2017

LEMBAR PENGESAHAN

PERAMALAN JUMLAH PENERIMAAN MASA PPh PASAL 21 DI KANTOR PELAYANAN PAJAK PRATAMA SURABAYA GUBENG

TUGAS AKHIR

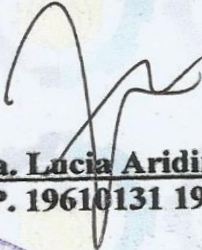
Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Ahli Madya Pada
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember

Oleh :

PRATIWI PENTA ATRIVI
NRP 1314 030 009

SURABAYA, JULI 2017

Menyetujui,
Pembimbing Tugas Akhir



Dra. Lucia Aridinanti, M.T
NIP. 19610131 198701 2 001

Mengetahui,
Kepala Departemen Statistika Bisnis
Fakultas Vokasi ITS,



Dr. Wahyu Wibowo, S.Si, M.Si
NIP. 19740328 199802 1 001

Halaman ini sengaja dikosongkan

PERAMALAN JUMLAH PENERIMAAN MASA PPh PASAL 21 DI KANTOR PELAYANAN PAJAK PRATAMA SURABAYA GUBENG

Nama : Pratiwi Penta Atrivi
NRP : 1314 030 009
Departemen : Statistika Bisnis ITS
Pembimbing : Dra. Lucia Aridinanti, M.T

ABSTRAK

Indonesia dapat diibaratkan sebagai sebuah rumah tangga yang besar, dalam memenuhi seluruh pembiayaan pengeluaran kebutuhan pastilah membutuhkan banyak dana. Indonesia menggali pendapatan negara yang dimilikinya, agar penyelenggaraan kepentingan umum dapat berjalan dengan baik. Sektor pajak merupakan sektor penerimaan yang paling potensial karena 70% penerimaan negara berasal dari pajak. Menurut Direktorat Jendral Pajak target penerimaan pajak yang dianggarkan oleh APBN sebagian besar pencapaian targetnya didominasi oleh sektor PPh. Dimana dalam pajak penghasilan tersebut terdapat pajak penghasilan pasal 21. Namun dengan diterapkannya sistem perpajakan self assesment di Indonesia memungkinkan kurang disiplinnya para wajib pajak dalam melaporkan SPT. Salah satu kota yang memiliki rata-rata rasio pajak tertinggi di Indonesia adalah Surabaya. Di Surabaya terdiri dari 13 kantor pelayanan pajak salah satunya adalah Kantor Pelayanan Pajak Pratama Surabaya Gubeng. Jumlah realisasi penerimaan pajak penghasilan (PPh) pasal 21 mengalami kenaikan dan penurunan serta di beberapa tahun jumlah penerimaannya tidak mencapai target penerimaan pajak yang telah ditetapkan oleh Direktorat Jenderal Pajak. Metode yang dapat digunakan dalam perhitungan jumlah penerimaan masa PPh pasal 21 adalah peramalan dengan metode ARIMA Box-Jenkins. Data yang digunakan pada penelitian ini adalah data jumlah penerimaan masa PPh Pasal 21 bulan Januari tahun 2012 sampai Desember 2016. Model terbaik yang diperoleh adalah ARIMA (0,1,[12]). Nilai peramalan tertinggi diperkirakan terjadi pada bulan Desember 2017 dan terendah pada bulan Maret 2017.

Kata Kunci : ARIMA, Peramalan, PPh Pasal 21.

Halaman ini sengaja dikosongkan

FORECASTING AMOUNT OF TAX REVENUES ARTICLE 21 IN THE TAX SERVICE OFFICE PRAMATA SURABAYA GUBENG

Name : Pratiwi Penta Atrivi
NRP : 1314 030 009
Department : Business Statistics ITS
Supervisor : Dra. Lucia Aridinanti, MT

ABSTRACT

Indonesia can be regarded as a large household, in fulfilling all the financing needs of spending would require a lot of funds. Indonesia is exploring the state revenue it has, so the implementation of the public interest can run well. The tax sector is the most potential revenue sector because 70% of state revenue comes from taxes. According to the Directorate General of Taxation, the target of tax revenues budgeted by the state budget most of the achievement of its target is dominated by the PPh sector. Where in the income tax there is income tax article 21. However, with the implementation of the self-assessment tax system in Indonesia allows less taxpayer discipline in reporting tax returns. One of the cities with the highest tax ratio in Indonesia is Surabaya. In Surabaya consist of 13 service offices of tax one of them is Tax Service Office Pratama Surabaya Gubeng. The amount of realization of income tax revenues (PPh) article 21 has increased and decreased as well as in several years the amount of income does not reach the target of tax revenue that has been determined by the Directorate General of Taxes. The method that can be used in calculating the amount of receipt of Income Tax Article 21 is forecasting by ARIMA Box-Jenkins method. The data used in this study is the data on the amount of income during the period of Article 21 in January 2012 until December 2016. The best model obtained is ARIMA (0,1,[12]). The highest forecasting value is expected to occur in December 2017 and the lowest in March 2017.

Keywords : ARIMA, Forecasting, PPh Article 21.

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur kehadiran Allah SWT yang telah memberikan rahmat, taufiq, dan hidayah-Nya sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul “**Peramalan Jumlah Penerimaan Masa PPh Pasal 21 Di Kantor Pelayanan Pajak Pratama Surabaya Gubeng**”.Penyusunan Tugas Akhir ini dapat terselesaikan dengan baik dan lancar karena tidak lepas dari dukungan berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Ibu Dra. Lucia Aridinanti, MT selaku dosen pembimbing yang telah membimbing, mengarahkan, dan memberikan dukungan dalam menyelesaikan Tugas Akhir ini.
2. Ibu Dra. Sri Mumpuni Retnaningsih, MT dan Ibu Ir. Sri Pingit Wulandari, MS selaku dosen penguji dan validator yang telah memberikan saran dan kritik yang membangun untuk menyelesaikan Tugas Akhir ini.
3. Bapak Dr. Wahyu Wibowo, S.Si, M.Si selaku Kepala Departemen Statistika Bisnis dan Ibu Ir. Sri Pingit Wulandari, MS selaku Kepala Program Studi Diploma III Departemen Statistika Bisnis Fakultas Vokasi ITS yang telah membimbing dan memotivasi penulis selama menjadi mahasiswa.
4. Seluruh dosen Departemen Statistika Bisnis ITS yang telah memberikan ilmu selama penulis menempuh pendidikan, beserta seluruh karyawan Departemen Statistika Bisnis ITS yang telah membantu kelancaran dan kemudahan dalam pelaksanaan kegiatan perkuliahan.
5. Kepala dan karyawan Bidang Penyuluhan, Pelayanan dan Hubungan Masyarakat Kantor wilayah DJP Jawa Timur I yang sudah memberikan ijin penulis untuk mengambil data keperluan Tugas Akhir ini.
6. Kepala dan Karyawan Bidang Pengolahan Data dan Informasi serta Bidang Subbag Umum dan Kepatuhan

internal yang sudah membantu memberikan data keperluan Tugas Akhir ini.

7. Dinas Sosial Kalijudan Surabaya yang telah membantu biaya perkuliahan serta dukungan dan motivasi kepada penulis hingga penyelesaian Tugas Akhir ini.
8. Orang tua, keluarga, dan teman-teman yang selalu memberikan motivasi, dukungan dan doa dalam proses Tugas Akhir ini serta semua pihak tidak dapat disebutkan satu persatu oleh penulis.

Penulis menyadari bahwa laporan Tugas Akhir ini masih jauh dari kata sempurna, oleh karena itu penulis sangat mengharapkan kritik dan saran yang membangun agar berguna untuk perbaikan berikutnya.

Semoga laporan Tugas Akhir ini bermanfaat.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian.....	4
1.4 Batasan Masalah.....	4
1.5 Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA	7
2.1 Metode <i>Time Series</i>	7
2.2 Model ARIMA.....	8
2.2.1 Identifikasi Model ARIMA <i>Box-Jenkins</i>	11
2.2.2 Estimasi Parameter.....	13
2.2.3 Pemeriksaan Parameter	15
2.2.4 Pengujian Asumsi Residual.....	16
2.2.5 Pemilihan Model Terbaik.....	17
2.3 Pajak.....	19
2.4 Pajak Penghasilan (PPh) Pasal 21.....	19
2.5 SPT.....	19
BAB III METODOLOGI PENELITIAN	21
3.1 Variabel Penelitian dan Struktur Data.....	21
3.2 Langkah Analisis.....	22
BAB IV ANALISIS DAN PEMBAHASAN	25
4.1 Pemodelan Penerimaan Masa PPh Pasal 21.....	25
4.1.1 Identifikasi Model Penerimaan Masa PPh Pasal 21.....	26

4.1.2 Estimasi Parameter Penerimaan Masa PPh	
Pasal 21.....	30
4.1.3 Pemeriksaan Residual Penerimaan Masa	
PPh Pasal 21.....	32
4.1.4 Pemilihan Model Terbaik Penerimaan Masa	
PPh Pasal 21.....	33
4.2 Peramalan Jumlah Penerimaan Masa PPh	
Pasal 21.....	34
BAB V KESIMPULAN DAN SARAN	37
5.1 Kesimpulan.....	37
5.2 Saran.....	37
DAFTAR PUSTAKA	
LAMPIRAN	
BIODATA PENULIS	

DAFTAR GAMBAR

	Halaman
Gambar 3.1 Diagram Alir.....	23
Gambar 4.1 <i>Time Series Plot</i> Penerimaan Masa PPh Pasal 21	25
Gambar 4.2 <i>Time Series Plot</i> Penerimaan Masa PPh Pasal 21 <i>Data In Sample</i>	26
Gambar 4.3 Plot <i>Box-Cox</i> Penerimaan Masa PPh Pasal 21....	27
Gambar 4.4 Plot ACF Penerimaan Masa PPh Pasal 21	28
Gambar 4.5 <i>Time series Plot</i> Penerimaan Masa PPh Pasal 21 Hasil <i>Differencing</i>	28
Gambar 4.6 (a) Plot ACF dan (b) Plot PACF <i>Data Penerimaan Masa PPh Pasal 21</i>	29

Halaman ini sengaja dikosongkan

DAFTAR TABEL

	Halaman
Tabel 2.1	Transformasi <i>Box-Cox</i>8
Tabel 2.2	Pola ACF dan PACF13
Tabel 3.1	Struktur Data Penerimaan Pajak21
Tabel 4.1	Hasil Pemodelan ARIMA31
Tabel 4.2	Hasil Pengujian Residual <i>White Noise</i>32
Tabel 4.3	Hasil Pengujian Residual Berdistribusi Normal33
Tabel 4.4	Kriteria Pemilihan Model Terbaik33
Tabel 4.5	Ramalan Jumlah Penerimaan Tahun 2017.....35

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Penerimaan Masa PPH Pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng.	41
Lampiran 2. <i>Output</i> Minitab ACF	43
Lampiran 3. <i>Output</i> Minitab PACF	45
Lampiran 4. Model ARIMA yang terbentuk	47
Lampiran 5. <i>Syntax</i> SAS Model ARIMA (0,1,1)	50
Lampiran 6. <i>Syntax</i> SAS Model ARIMA (0,1,[12]).....	51
Lampiran 7. <i>Syntax</i> SAS Model ARIMA (0,1,0)	52
Lampiran 8. <i>Syntax</i> SAS Model ARIMA ([2],1,0).....	53
Lampiran 9. <i>Syntax</i> SAS Model ARIMA ([11],1,0).....	54
Lampiran 10. <i>Syntax</i> SAS Model ARIMA (1,1,1)	55
Lampiran 11. <i>Syntax</i> SAS Model ARIMA ([2],1,1).....	56
Lampiran 12. <i>Syntax</i> SAS Model ARIMA ([11],1,1).....	57
Lampiran 13. <i>Syntax</i> SAS Model ARIMA (1,1,[12]).....	58
Lampiran 14. <i>Syntax</i> SAS Model ARIMA ([2],1,[12])	59
Lampiran 15. <i>Syntax</i> SAS Model ARIMA (11,1,[12]).....	60
Lampiran 16. <i>Syntax</i> SAS Model ARIMA (0,1,[1,12]).....	61
Lampiran 17. <i>Syntax</i> SAS Model ARIMA ([1,2,11],1,0).....	62
Lampiran 18. <i>Syntax</i> SAS Model ARIMA (1,1,[1,12]).....	63
Lampiran 19. <i>Syntax</i> SAS Model ARIMA ([2],1,[1,12])	64
Lampiran 20. <i>Syntax</i> SAS Model ARIMA [11],1,[1,12])	65
Lampiran 21. <i>Syntax</i> SAS Model ARIMA ([1,2],1,1).....	66
Lampiran 22. <i>Syntax</i> SAS Model ARIMA ([1,2],1,[12])	67
Lampiran 23. <i>Syntax</i> SAS Model ARIMA ([1,11],1,1).....	68
Lampiran 24. <i>Syntax</i> SAS Model ARIMA ([1,11],1,[12])	69
Lampiran 25. <i>Syntax</i> SAS Model ARIMA ([2,11],1,1).....	70
Lampiran 26. <i>Syntax</i> SAS Model ARIMA ([2,11],1,[12])	71
Lampiran 27. <i>Syntax</i> SAS Model ARIMA [1,2,11],1,1)	72

Lampiran 28.	<i>Syntax</i> SAS Model ARIMA ([1,2,11],1,[12])	73
Lampiran 29.	<i>Output</i> SAS Model ARIMA (0,1,1)	74
Lampiran 30.	<i>Output</i> SAS Model ARIMA (0,1,[12])	75
Lampiran 31.	<i>Output</i> SAS Model ARIMA (0,1,0)	76
Lampiran 32.	<i>Output</i> SAS Model ARIMA ([2],1,0)	77
Lampiran 33.	<i>Output</i> SAS Model ARIMA ([11],1,0)	78
Lampiran 34.	<i>Output</i> SAS Model ARIMA (1,1,1)	79
Lampiran 35.	<i>Output</i> SAS Model ARIMA ([2],1,1)	80
Lampiran 36.	<i>Output</i> SAS Model ARIMA ([11],1,1)	81
Lampiran 37.	<i>Output</i> SAS Model ARIMA (1,1,[12])	82
Lampiran 38.	<i>Output</i> SAS Model ARIMA ([2],1,[12])	83
Lampiran 39.	<i>Output</i> SAS Model ARIMA (11,1,[12])	84
Lampiran 40.	<i>Output</i> SAS Model ARIMA (0,1,[1,12])	85
Lampiran 41.	<i>Output</i> SAS Model ARIMA ([1,2,11],1,0)	86
Lampiran 42.	<i>Output</i> SAS Model ARIMA (1,1,[1,12])	87
Lampiran 43.	<i>Output</i> SAS Model ARIMA ([2],1,[1,12])	88
Lampiran 44.	<i>Output</i> SAS Model ARIMA [11],1,[1,12])	89
Lampiran 45.	<i>Output</i> SAS Model ARIMA ([1,2],1,1)	90
Lampiran 46.	<i>Output</i> SAS Model ARIMA ([1,2],1,[12])	91
Lampiran 47.	<i>Output</i> SAS Model ARIMA ([1,11],1,1)	92
Lampiran 48.	<i>Output</i> SAS Model ARIMA ([1,11],1,[12])	93
Lampiran 49.	<i>Output</i> SAS Model ARIMA ([2,11],1,1)	94
Lampiran 50.	<i>Output</i> SAS Model ARIMA ([2,11],1,[12])	95
Lampiran 51.	<i>Output</i> SAS Model ARIMA [1,2,11],1,1)	96
Lampiran 52.	<i>Output</i> SAS Model ARIMA ([1,2,11],1,[12])	97
Lampiran 53.	Perhitungan Manual RMSE dan MAPE Model ARIMA (0,1,[12])	98
Lampiran 54.	Perhitungan Manual RMSE dan MAPE Model ARIMA (0,1,[1,12])	100
Lampiran 55.	<i>Syntax</i> SAS Model ARIMA (0,1,[12]) untuk Peramalan	102

Lampiran 56. <i>Output</i> SAS Peramalan dengan Model ARIMA (0,1,[12])	103
Lampiran 57. <i>Syntax</i> SAS Peramalan Target 2018	105
Lampiran 58. <i>Output</i> SAS Peramalan Target 2018	106
Lampiran 59. <i>Output</i> SAS Contoh Model ARIMA Jika Di Transformasi	107
Lampiran 60. Surat Pemberian Ijin Penelitian	108
Lampiran 61. Surat Pernyataan Keaslian Data	109

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

1.1 Latar Belakang

Negara dapat diibaratkan sebagai sebuah rumah tangga yang besar, dalam memenuhi seluruh pembiayaan pengeluaran kebutuhan bagi penyelenggaraan kepentingan umum pastilah membutuhkan banyak dana. Seperti halnya Indonesia, salah satu negara besar dengan jumlah mencapai ratusan juta penduduk. Pengeluaran yang harus dipenuhi dengan jumlah penduduk yang begitu besar juga tidak sedikit. Untuk membiayai pengeluaran tersebut, Indonesia menggali pendapatan negara yang dimilikinya, agar penyelenggaraan kepentingan umum dapat berjalan dengan baik. Pajak merupakan salah satu pendapatan dalam negeri yang utama di Indonesia. Pembayaran pajak merupakan suatu kewajiban yang seharusnya dilakukan oleh rakyat dan sangat penting sifatnya, karena dengan uang pembayaran pajak tersebut negara dapat memberikan pelayanan-pelayanan dan fasilitas-fasilitas untuk rakyatnya. Jika rakyat dan pemerintah saling bekerja sama dalam memenuhi keewajiban dan tugasnya, maka pembayaran dan pelaporan pajak akan berjalan dengan baik sehingga uang dari pajak selanjutnya dapat digunakan sebaik mungkin oleh pemerintahan untuk rakyat.

Sektor pajak merupakan sektor penerimaan dalam negeri yang paling potensial dibandingkan dengan sektor penerimaan dalam negeri lainnya karena 70% penerimaan negara berasal dari pajak dan sisanya 30% berasal dari non-pajak. Penerimaan dari sektor pajak terbagi menjadi 2 (dua) golongan yaitu dari pajak langsung, contohnya pajak penghasilan (PPh), dan pajak tidak langsung, contohnya pajak pertambahan nilai (PPN), bea materai dan bea balik nama. Dilihat dari segi penerimaannya, pajak penghasilan memberikan kontribusi yang paling besar bagi negara, hal ini juga dikarenakan jumlah penduduk Indonesia yang cukup banyak. Menurut Direktorat Jendral Pajak (Dirjen Pajak) target penerimaan pajak yang dianggarkan oleh APBN sebagian

besar pencapaian targetnya didominasi oleh sektor PPh. Dimana dalam pajak penghasilan tersebut terdapat pajak penghasilan pasal 21 (PPh pasal 21) (Direktorat Jenderal Pajak, 2016). Pajak Penghasilan (PPh) Pasal 21 merupakan pajak atas penghasilan yang diterima atau diperoleh oleh orang pribadi sehubungan dengan pekerjaan, jasa atau kegiatan yang dilakukannya. PPh Pasal 21 merupakan salah satu jenis pajak yang dipungut Negara melalui mekanisme pemotongan (*withholding tax*). Kewajiban untuk melakukan pengadministrasian pemotongan PPh Pasal 21 dari penghitungan, penyetoran, dan pelaporan pajak berada di pihak pemberi kerja sebagai Wajib Pajak Orang Pribadi atau Wajib Pajak Badan, termasuk Bentuk Usaha Tetap (Direktorat Jenderal Pajak, 2016).

Kewajiban pemotongan PPh Pasal 21 umumnya akan terjadi setiap bulan minimal atas penghasilan yang dibayarkan kepada pegawai tetap. Namun dengan diterapkannya sistem perpajakan *self ascement* (wajib pajak menghitung, menyetorkan, dan melaporkan pajaknya sendiri) di Indonesia memungkinkan kurang disiplinnya para wajib pajak dalam melaporkan SPT (surat pemberitahuan). SPT dibedakan menjadi dua yaitu SPT masa (bulanan) yang dilaporkan oleh pihak pemotong (Badan) dan SPT tahunan (Mardiasmo, 2003). Setiap tahunnya penerimaan PPh pasal 21 mengalami penurunan. Tahun 2014 penerimaan PPh pasal 21 sebesar Rp 93,808 triliun, tahun 2015 turun menjadi 93,485 triliun dan tahun 2016 turun 3,04% menjadi Rp 90,644 triliun. Dari 30.044.103 WP (wajib pajak) terdaftar, hanya 60,27% atau sebanyak 10.945.567 WP yang melaporkan SPT ((Direktorat Jenderal Pajak, 2016).

Salah satu kota yang memiliki rata-rata rasio pajak tertinggi di Indonesia adalah Surabaya. Di Surabaya terdiri dari 13 kantor pelayanan pajak salah satunya adalah Kantor Pelayanan Pajak Pratama Surabaya Gubeng. Dalam hal ini jumlah realisasi penerimaan pajak penghasilan (PPh) pasal 21 mengalami kenaikan dan penurunan serta di beberapa tahun jumlah

penerimaannya tidak mencapai target penerimaan pajak yang telah ditetapkan oleh Direktorat Jenderal Pajak.

Metode yang dapat digunakan dalam perhitungan jumlah penerimaan masa PPh pasal 21 adalah peramalan dengan metode *ARIMA Box-Jenkins*. Peramalan merupakan prediksi nilai-nilai yang akan datang berdasarkan pada nilai-nilai yang diketahui sebelumnya. Dengan melakukan prediksi menggunakan *ARIMA Box-Jenkins* yang tepat maka akan berdampak pada ketepatan dalam pengambilan kebijakan yang akan datang. Dengan demikian jumlah penerimaan masa PPh pasal 21 sangat berpengaruh pada prediksi jumlah penerimaan selanjutnya dan berdampak pada pendapatan di Kantor Pelayanan Pajak Pratama Surabaya Gubeng.

1.2 Rumusan Permasalahan

Pembayaran pajak merupakan suatu kewajiban yang seharusnya dilakukan oleh wajib pajak berdasarkan undang-undang yang telah ditetapkan. Direktorat Jendral Pajak memiliki target penerimaan pajak yang dianggarkan dalam APBN setiap tahunnya yang sebagian besar pencapaian targetnya didominasi oleh sektor PPh. Pajak Penghasilan (PPh) masa Pasal 21 wajib dilaporkan oleh pihak pemotong (Badan) atas penghasilan yang dibayarkan kepada pegawai tetap. Namun, dengan diterapkannya sistem perpajakan *self assesment* (wajib pajak menghitung, menyetorkan, dan melaporkan pajaknya sendiri) di Indonesia memungkinkan kurang disiplinnya para wajib pajak dalam melaporkan SPT yang berakibat jumlah realisasi penerimaan pajak tidak mencapai target penerimaan pajak. Berdasarkan masalah tersebut perlu dilakukan peramalan jumlah penerimaan masa PPh Pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng apakah telah sesuai dengan target yang telah ditetapkan oleh Direktorat Jenderal Pajak serta untuk pengambilan kebijakan selanjutnya serta untuk menentukan target selanjutnya (tahun 2018). Sehingga diperoleh rumusan masalah pada penelitian ini diantaranya adalah

1. Bagaimana model untuk peramalan jumlah penerimaan masa (bulanan) PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng bulan Januari sampai Desember Tahun 2017 ?
2. Berapa jumlah penerimaan masa (bulanan) PPh pasal 21 di Kantor Pelayanan Pajak Surabaya Gubeng bulan Januari sampai Desember Tahun 2017 ?

1.3 Tujuan Penelitian

Menjawab permasalahan yang ada maka tujuan dari penelitian ini adalah

1. Menentukan model untuk peramalan jumlah penerimaan masa (bulanan) PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng bulan Januari sampai Desember Tahun 2017.
2. Meramalkan jumlah penerimaan masa (bulanan) PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng bulan Januari sampai Desember Tahun 2017.

1.4 Batasan Masalah

Berdasarkan dari tujuan penelitian ini maka batasan yang ada dalam penelitian ini adalah jumlah penerimaan masa (bulanan) PPh Pasal 21 tahun 2012, 2013, 2014, 2015 dan 2016 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng.

1.5 Manfaat Penelitian

Manfaat yang dapat diperoleh dari penelitian ini adalah mendapatkan model peramalan terbaik dan hasil peramalan jumlah penerimaan masa (bulanan) PPh pasal 21 bulan Januari sampai Desember Tahun 2017 yang dapat digunakan Kantor Pelayanan Pajak Pratama Surabaya Gubeng sebagai bahan pertimbangan untuk mengambil kebijakan atau keputusan dan juga bisa mengaktifkan siapa saja wajib pajak yang belum membayarkan pajak untuk membayar pajak berdasarkan

peramalan jumlah penerimaan yang diperoleh dan untuk menentukan target penerimaan tahun 2018.

Halaman ini sengaja dikosongkan

BAB II TINJAUAN PUSTAKA

2.1 Metode *Time Series*

Deret Waktu (*Time series*) adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadiannya dengan interval waktu yang tetap (Wei, 2006).

Time series dapat juga diartikan sebagai serangkaian data yang didapatkan berdasarkan pengamatan dari suatu kejadian pada urutan waktu terjadinya. Waktu kejadian bisa merupakan periode dalam satuan detik, menit, jam, hari, bulan, tahun dan periode waktu yang lainnya, semuanya itu merupakan serangkaian data pengamatan yang didasarkan pada waktu kejadian dengan interval waktu tertentu yang lebih dikenal dengan *time series* (Cryer & Chan, 2008), dimana setiap pengamatan dinyatakan sebagai variabel random Z_t yang didapatkan berdasarkan indeks waktu tertentu (t_i) sebagai urutan waktu pengamatan, sehingga penulisan data *time series* adalah $Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{tn}$. Dalam metode *time series* ada beberapa hal yang perlu diperhatikan, yaitu kestasioneran data, fungsi autokorelasi dan fungsi autokorelasi parsial.

Stasioneritas *time series* merupakan suatu keadaan jika proses pembangkitan yang mendasari suatu deret berkala didasarkan pada nilai tengah konstan dan nilai varians konstan (Makridakis, Wheelwright, & McGee, 1999). Untuk memeriksa kestasioneran dapat menggunakan plot data *time series* antara nilai Z_t yang menunjukkan data aktual pada periode ke- t . Jika plot *time series* berfluktuasi di sekitar garis sejajar dengan sumbu periode (t) maka dikatakan deret stasioner dalam *mean*. Dikatakan stasioner dalam *mean* saat ACF menunjukkan pola yang turun cepat. Dalam suatu data kemungkinan data tersebut tidak stationer hal ini dikarenakan *mean* tidak konstan atau variansnya tidak konstan sehingga untuk menghilangkan ketidakstasioneran terhadap *mean*, maka data tersebut dapat dibuat lebih mendekati

stasioner dengan cara melakukan penggunaan metode perbedaan atau *differencing* (Makridakis, Wheelwright, & McGee, 1999).

$$Z_t' = Z_t - Z_{t-1}$$

Data dikatakan stasioner dalam varians apabila *rounded value* (λ) adalah 1. Jika data tidak stasioner dalam varians ($\lambda \neq 0$), maka dapat distasionerkan dengan menggunakan transformasi. Pada umumnya untuk menstasionerkan varians digunakan *power transformation* (Wei, 2006) sebagai berikut :

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}, \text{ berlaku untuk } \lambda \neq 0$$

dimana λ merupakan parameter transformasi dari transformasi *Box-Cox*. Ketika $\lambda = 0$, dilakukan pendekatan berikut.

$$\lim_{\lambda \rightarrow 0} T(Z_t) = \lim_{\lambda \rightarrow 0} T(Z_t)^{(\lambda)} = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln Z_t$$

Nilai λ yang dipilih adalah nilai λ yang meminimalkan jumlah kuadrat residual sehingga memiliki *variens* yang minimum. Transformasi *Box-Cox* (Wei, 2006) untuk beberapa nilai λ yang sering digunakan dapat dilihat pada Tabel 2.1.

Tabel 2.1 Transformasi *Box-Cox*

Nilai estimasi λ	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t (tidak ada transformasi)

(Sumber : Wei, 2006)

Salah satu metode yang dapat digunakan dalam pendugaan parameter λ pada transformasi *Box-cox* adalah dengan metode *Maximum Likelihood Estimation* (MLE). Nilai λ yang dipilih adalah yang dapat meminimumkan jumlah kuadrat residual sehingga varians yang dimiliki dapat minimum (Wei, 2006).

2.2 Model ARIMA

ARIMA (*Autoregressive Integrated Moving Average*)

merupakan salah satu model dalam *time series*. Model ini terdiri dari komponen AR (*Autoregressive*), MA (*Moving Average*), atau ARMA (*Autoregressive Moving Average*), dan jika data tidak stasioner dalam mean maka dilakukan proses differencing sehingga terdapat komponen *integrated* (I) (Wei, 2006). Terdapat dua model ARIMA yaitu model ARIMA musiman dan non musiman. Bentuk umum dari model ARIMA adalah sebagai berikut :

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (2.1)$$

Sedangkan model ARIMA yang musiman adalah sebagai berikut :

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.2)$$

Dengan

p = orde Autoregressive (AR) non musiman

q = orde Moving Average (MA) non musiman

P = orde Autoregressive (AR) musiman

Q = orde Moving Average (MA) musiman

$\phi_p(B)$ = koefisien komponen AR orde p

$\theta_q(B)$ = koefisien komponen MA orde q

$\Phi_P(B^S)$ = koefisien komponen AR musiman S orde P

$\Theta_Q(B^S)$ = koefisien komponen MA musiman S orde Q

$(1-B)^d$ = *differencing* orde d

$(1-B^S)^D$ = *differencing* musiman S dengan orde D

a_t = residual white noise dengan *mean* 0 dan *varians* σ_a^2

Model *Box-Jenkins* merupakan salah satu teknik peramalan model *time series* yang hanya berdasarkan perilaku data variabel yang diamati. Model *Box-Jenkins* secara teknis dikenal sebagai model *Autoregressive Integrated Moving Average* atau ARIMA (Makridakis, Wheelwright, & McGee, 1999). Prosedur *Box-Jenkins* digunakan untuk memilih model ARIMA yang sesuai pada data *time series*. Syarat yang harus dipenuhi untuk membuat

model peramalan yaitu data telah stasioner.

Model autoregresif (AR) menunjukkan adanya hubungan antara suatu nilai pada waktu sekarang dengan nilai pada waktu sebelumnya dengan menambah suatu nilai acak. Model *moving average* (MA) menunjukkan adanya hubungan anatara nilai pada waktu sekarang dengan nilai residual pada waktu sebelumnya (Wei, 2006).

Proses autoregresif sesuai dengan namanya adalah proses hasil regresi dengan dirinya sendiri. Bentuk umum dari proses autoregresif tingkat p atau AR (p) adalah

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.3)$$

yang menunjukkan bahwa nilai sekarang suatu proses dapat dinyatakan sebagai jumlah tertimbang dari nilai-nilai p yang lalu ditambah satu *error* yang random sekarang. Dalam hal ini diasumsikan a_t adalah independen dengan Z_{t-1}, Z_{t-2}, \dots . Jadi dapat dipandang Z_t diregresikan pada p nilai Z yang lalu. Persaman (2.3) di atas biasanya juga ditulis dalam bentuk

$$\phi(B) \overset{\bullet}{Z}_t = a_t \quad (2.4)$$

dengan $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ yang dikenal sebagai

operator AR(p). Dengan $\overset{\bullet}{Z}_t = Z_t - \mu$ dan μ adalah suatu konstanta rata-rata.

Bentuk umum dari proses *moving average* tingkat q atau MA(q) didefinisikan sebagai

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.5)$$

Dimana a_t adalah independen dan berdistribusi normal dengan *mean* 0 dan *varians* σ_a^2 . Persaman (2.5) ini dapat juga ditulis dalam bentuk

$$Z_t = \theta(B) a_t \quad (2.6)$$

dengan $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ yang dikenal sebagai operator MA(q).

Mean dan *varians* dari model MA (q) ini selanjutnya dapat dihitung, yaitu

$$E(Z_t) = E(a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}) = 0$$

dan

$$\begin{aligned} \text{var}(Z_t) &= \text{var}(a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}) \\ \gamma_0 &= (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \sigma_a^2 \end{aligned} \quad (2.7)$$

Untuk q berhingga, maka proses MA ini akan selalu stasioner.

Proses MA(q) dikatakan *invertible*, dapat ditulis dalam bentuk AR tingkat tak berhingga, jika harga koefisien-koefisien π merupakan deret yang konvergen, yaitu hanya apabila akar-akar $\pi(B) = 0$ semuanya terletak di luar lingkaran satuan, suatu syarat yang serupa dengan syarat stasioneritas dari suatu proses AR(p).

Suatu perluasan yang dapat diperoleh dari model AR dan MA adalah model campuran yang berbentuk

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.8)$$

yang dinamakan model ARMA(p, q). Model ini biasanya ditulis dengan

$$\phi(B)Z_t = \theta(B)a_t \quad (2.9)$$

Syarat-syarat stasioneritas dan invertibilitas memerlukan akar-akar dari $\phi(B) = 0$ dan $\theta(B) = 0$ terletak di luar lingkaran satuan.

Tahapan dalam membentuk model ARIMA adalah identifikasi, estimasi parameter, pemeriksaan diagnostik, menentukan model terbaik, dan peramalan (Box, Jenkins, & Reinsel, 2008). Berikut adalah tahapan-tahapan membentuk model ARIMA :

2.2.1 Identifikasi Model ARIMA Box-Jenkins

Identifikasi model ARIMA *Box-Jenkins* dapat dijadikan

sebagai langkah dalam mengidentifikasi adanya ketidakstasioneran model. Bila tidak stasioner dalam *mean* maka dapat di *differencing* dan jika tidak stasioner dalam varians maka dapat ditransformasi *Box-Cox*. Setelah data sudah stasioner dalam *mean* dan varian maka selanjutnya membuat plot ACF dan PACF yang digunakan untuk mengidentifikasi model awal ARIMA.

Tabel 2.2 merupakan identifikasi model time series non musiman maupun yang musiman berdasarkan ACF dan PACF untuk proses yang stasioner. Pola data musiman terjadi bilamana suatu deret dipengaruhi oleh faktor musiman yaitu pola musim yang berulang pada periode tertentu tertentu.

a. Autocorrelation Funtion (ACF)

Autocorrelation Funtion merupakan suatu proses korelasi pada data time series antara Z_t dan Z_{t+k} . ACF menunjukkan hubungan bersama (mutual dependence) antara nilai deret berkala dengan periode waktu yang berlainan (Makridakis, Wheelwright, & McGee, 1999). Pada data yang telah stasioner dengan nilai rata-rata dan varians yang konstan dapat ditunjukkan pada persamaan berikut (Wei, 2006).

$$\hat{\gamma}_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.10)$$

Dan fungsi autokorelasi adalah sebagai berikut

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 0, 1, 2, \dots \quad (2.11)$$

Keterangan :

$\hat{\gamma}_k$: Fungsi autokovarian pada lag ke- k

$\hat{\rho}_k$: Fungsi autokorelasi pada lag ke- k

b. Partial Autocorrelation Function (PACF)

Partial autocorrelation function (PACF) digunakan untuk mengukur tingkat keeratan hubungna antara Z_t dan Z_{t+k} setelah pengaruh $Z_{t+1}, Z_{t+1}, \dots, Z_{t+k-1}$ dihilangkan (Wei, 2006). Fungsi

PACF yang ditunjukkan oleh persamaan 2.12 sebagai berikut.

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.12)$$

Keterangan :

$\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} = \hat{\phi}_{k+1,k+1} \hat{\phi}_{k+k+1-j}$ untuk $j=1,2,\dots,k$

$\hat{\rho}_{k+1}$: Fungsi autokorelasi dari sampel setelah lag ke- k

$\hat{\rho}_j$: Fungsi autokorelasi dari sampel setelah lag ke- j

Tabel 2.2 Pola ACF dan PACF

Model	ACF	PACF
AR (p)	Turun cepat secara eksponensial	Terpotong setelah lag p
MA (q)	Terpotong setelah lag q	Turun cepat secara eksponensial
AR (p) atau MA (q)	Terpotong setelah lag q	Terpotong setelah lag p
ARMA (p,q)	Turun cepat secara eksponensial	Turun cepat secara eksponensial

2.2.2 Estimasi Parameter

Dalam penaksiran parameter, salah satu metode yang dapat digunakan adalah *Conditional Least Square* (CLS). Metode CLS bekerja dengan membuat error yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat *error* (SSE). Cryer dan Chan (2008) maka *least square* estimation pada model AR(1) dapat dinyatakan sebagai berikut

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t \quad (2.13)$$

Sehingga

$$S(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.14)$$

Berdasarkan metode *least square*, taksiran ϕ dan μ dilakukan dengan meminimumkan $S(\phi, \mu)$ dengan taksiran

sebagai berikut

$$\hat{\mu} = \frac{\sum_{t=2}^n Z_t - \hat{\phi}_1 \sum_{t=2}^n Z_{t-1}}{(n-1)(n-\phi)} \quad (2.15)$$

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.16)$$

Pada model MA, dimisalkan MA(1) *least square estimation* adalah sebagai berikut.

$$S(\theta) = \sum_{t=2}^n (a_t)^2 = \sum_{t=1}^n [(Z_t + \theta Z_{t-1} + \theta^2 Z_{t-2} + \dots)]^2 \quad (2.17)$$

Secara implisit, $a_t = a_t(\theta)$ adalah fungsi dari observasi dan parameter θ yang tidak diketahui. Masalah kuadrat kecil yang bersifat non linear di parameter, yang berarti tidak akan dapat meminimalkan $S(\theta)$ dengan mengambil turunan yang sehubungan dengan θ , diatur menjadi 0 dan diselesaikan. Dalam mengatasi masalah ini, dipertimbangkan mengevaluasi $S(\theta)$ untuk setiap nilai θ . Hanya Z_t observasi yang diamati, Z_1, Z_2, \dots, Z_n . Persamaannya adalah sebagai berikut.

$$a_t = Z_t + \theta Z_{t-1} \quad (2.18)$$

Menggunakan persamaan, a_1, a_2, \dots, a_n dapat dihitung untuk secara rekursif, jika memiliki nilai $a_1 = 0$. Pendekatan yang umum adalah menetapkan $a_0 = 0$. Nilai yang diharapkan bersyarat pada $a_0 = 0$, yang bisa didapatkan adalah sebagai berikut.

$$\begin{aligned} a_1 &= Z_1 \\ a_2 &= Z_2 + \theta a_1 \\ a_3 &= Z_3 + \theta a_2 \\ &\vdots \\ a_n &= Z_n + \theta a_{n-1} \end{aligned} \quad (2.19)$$

Demikian menghitung $S(\theta) = \sum_{t=1}^n (a_t)^2$, bersyarat pada $a_0 = 0$, untuk nilai tunggal yang diberikan pada θ (Cryer & Chan, 2008).

2.2.3 Pemeriksaan Parameter

Setelah mendapatkan estimasi parameter model, maka dilakukan pemeriksaan parameter untuk menguji suatu parameter model ARIMA layak atau tidak untuk masuk ke dalam suatu model. Maka uji signifikansi parameter dapat dilakukan sebagai berikut :

Hipotesis :

$H_0 : \phi_p = 0$ atau $\theta_q = 0$ (parameter tidak signifikan)

$H_1 : \phi_p \neq 0$ atau $\theta_q \neq 0$ (parameter signifikan)

Statistik uji dihitung dengan Persamaan 2.20 sebagai berikut :

$$t = \frac{\hat{\phi}}{SE(\hat{\phi}_p)} \text{ atau } t = \frac{\hat{\theta}}{SE(\hat{\theta}_q)} \quad (2.20)$$

$$SE = \frac{SD}{\sqrt{n}} \quad (2.21)$$

$$SD = \sqrt{(\text{var}\hat{\phi})^{-1}} \text{ atau } \sqrt{(\text{var}\hat{\theta})^{-1}} \quad (2.22)$$

$$\text{Var} = \frac{\sum_{t=1}^n (Z_t - \bar{Z})^2}{n-1} \quad (2.23)$$

Keterangan :

$\hat{\phi}$ atau $\hat{\theta}$: Estimasi parameter dalam setiap model

$SE(\hat{\phi}_p)$ atau $SE(\hat{\theta}_q)$: *Standart error* dari nilai estimasi parameter

SD : Standar deviasi

n : Banyaknya pengamatan

var : *Varians*

Dengan taraf signifikan sebesar α , dengan n adalah banyaknya observasi, p adalah jumlah parameter yang ditaksir maka H_0 ditolak jika $|t| > t_{\alpha/2, n-p}$ atau jika $p\text{-value} < \alpha$ (Wei, 2006).

2.2.4 Pengujian Asumsi Residual

Untuk mendapatkan model yang baik setelah model memiliki parameter yang signifikan selanjutnya melakukan pengujian terhadap residualnya yaitu melakukan pengujian apakah residual *white noise* dan residual berdistribusi normal.

$$a_t = Z_t - \hat{Z}_t \quad (2.24)$$

Keterangan :

Z_t = Data aktual pada periode ke- t

\hat{Z}_t = Data ramalan pada periode ke- t

a. Uji Asumsi Residual Berdistribusi Normal

Di bawah ini adalah cara pengujian kenormalan data dengan "*Kolmogorov Smirnov Test*" (Daniel, 1989).

Hipotesis :

H_0 : $F(a_t) = F_0(a_t)$ untuk semua nilai a_t (residual berdistribusi normal)

H_1 : $F(a_t) \neq F_0(a_t)$ untuk sekurang-kurangnya sebuah nilai a_t (residual tidak berdistribusi normal)

Statistik uji dihitung dengan Persamaan 2.25 sebagai berikut :

$$D = \sup_{a_t} |S(a_t) - F_0(a_t)| \quad (2.25)$$

Dengan taraf signifikan sebesar α , maka tolak H_0 jika $D > D_{(1-\alpha, n)}$ atau $p\text{-value} < \alpha$

Keterangan :

$S(a_t)$: Fungsi peluang kumulatif yang dihitung berdasarkan data sampel

$F_0(a_t)$: Fungsi peluang kumulatif dari distribusi normal

SUP : Nilai maksimum dari $|S(a_t) - F_0(a_t)|$

n : Banyaknya pengamatan

b. Uji Asumsi *White Noise*

Residual (a_t) yang *white noise* (residual independen dan identik) harus berupa variabel random. Uji yang digunakan untuk asumsi *white noise* adalah uji Ljung-Box (Wei, 2006). Dimana uji ini bertujuan untuk menguji residual memenuhi asumsi *white noise* digunakan uji sebagai berikut :

Hipotesis :

H_0 : $\rho_1 = \rho_2 = \dots = \rho_K = 0$ (residual memenuhi syarat *white noise*)

H_1 : Minimal ada satu $\rho_i \neq 0$ dengan $i = 1, 2, \dots, K$ (residual tidak memenuhi syarat *white noise*)

Statistik uji dihitung dengan Persamaan 2.26 sebagai berikut :

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \quad (2.26)$$

Dengan taraf signifikan sebesar α , maka H_0 ditolak jika

$Q > \chi^2_{(\alpha, K-p-q)}$ atau $p\text{-value} < \alpha$.

Keterangan:

n : Banyaknya pengamatan

$\hat{\rho}_k$: Taksiran autokorelasi residual lag ke-k, dapat dilihat pada persamaan 2.11

K : Lag maksimum

p dan q : Orde dari model ARIMA (p,q)

2.2.5 Pemilihan Model Terbaik

Pemilihan model terbaik atau seleksi model dilakukan jika terdapat lebih dari satu model *time series* yang layak dipakai yaitu dengan menggunakan dua pendekatan diantaranya pendekatan *in sampel* dan pendekatan *out sampel*. Pendekatan In Sampel dapat dilakukan berdasarkan nilai AIC, SBC, MSE, sedangkan

pemilihan data terbaik untuk data *out sample* dapat menggunakan kriteria RMSE.

a) **AIC (*Akaike's Information Criterion*)**

Pemilihan model terbaik melalui pendekatan *in sample* dapat dilakukan berdasarkan nilai AIC. Nilai AIC semakin kecil maka model yang didapatkan semakin baik dengan mempertimbangkan banyaknya parameter dalam model (Wei, 2006).

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.27)$$

b) **SBC (*Schwartz's Bayesian Criterion*)**

SBC juga merupakan cara pemilihan model terbaik dengan pendekatan *in sample*. Nilai SBC semakin kecil maka model yang didapatkan semakin baik (Wei, 2006).

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2.28)$$

c) **MAPE (*Mean Absolute Presentage Error*)**

MAPE digunakan untuk data *out sample*. Nilai berkaitan dengan presentase residual (Wei, 2006).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100\% \quad (2.29)$$

d) **MSE (*Mean Square Error*)**

MSE digunakan untuk mengetahui kesalahan rata-rata kuadrat dari tiap-tiap model yang layak (Wei, 2006).

$$MSE = \frac{\sum_{t=1}^n |Z_t - \hat{Z}_t|^2}{n} \quad (2.30)$$

e) **RMSE (*Root Mean Square Error*)**

RMSE merupakan salah satu indeks yang dapat digunakan untuk mengevaluasi ketepatan model time series dengan mempertimbangkan sisa perhitungan ramalan pada data *out sample*. Semakin kecil nilai RMSE maka model yang didapatkan semakin baik (Wei, 2006).

$$RMSE = \sqrt{\frac{\sum_{t=1}^n |Z_t - \hat{Z}_t|^2}{n}} \quad (2.31)$$

Keterangan :

n : Jumlah pengamatan

$\hat{\sigma}_a^2$: Estimasi maksimum likelihood dari σ_a^2

M : Banyaknya parameter dalam model

Z_t : Data aktual pada pada periode ke- t

\hat{Z}_t : Data ramalan pada pada periode ke- t

2.3 Pajak

Pajak adalah suatu kewajiban kenegaraan dan pengabdian peran aktif warga negara dan anggota masyarakat lainnya untuk membiayai berbagai keperluan negara berupa pembangunan nasional yang pelaksanaannya diatur dalam Undang-undang dan peraturan-peraturan untuk tujuan kesejahteraan dan negara (Judisseno, 1997).

2.4 Pajak Penghasilan (PPh) Pasal 21

Pajak penghasilan (PPh) pasal 21 merupakan pajak yang dikenakan atas penghasilan wajib orang pribadi dalam negeri berupa gaji, upah, honorarium, tunjangan dan pembayaran lainnya dengan nama apapun sehubungan dengan pekerjaannya atau jabatan, jasa dan kegiatan seperti yang telah diatur dalam pasal 21 undang – undang no 17 tahun 2000. Pemotong PPh pasal 21 adalah setiap orang pribadi atau badan yang diwajibkan oleh undang-undang untuk memotong pajak penghasilan 21 (Mardiasmo, 2003).

2.5 SPT

SPT adalah surat pemberitahuan setiap wajib pajak mengisi, menandatangani dan kemudian menyampaikan ke kantor KPP setempat. Secara garis besar SPT dibedakan menjadi 2 yaitu SPT masa dan SPT tahunan.

SPT masa adalah surat yang oleh wajib pajak digunakan untuk melaporkan perhitungan dan atau pembayaran pajak yang terutang dalam suatu masa (bulan) pajak atau pada suatu saat sedangkan SPT tahunan adalah surat yang oleh wajib pajak digunakan untuk melaporkan perhitungan dan atau pembayaran pajak yang terutang dalam suatu tahun pajak (Mardiasmo, 2003).

BAB III METODOLOGI PENELITIAN

3.1 Variabel Penelitian dan Struktur Data

Variabel penelitian yang diukur adalah jumlah penerimaan masa (bulanan) PPh Pasal 21 bulan Januari tahun 2012 sampai Desember 2016. Data penelitian ini merupakan data sekunder berupa hasil perekaman SPT jumlah penerimaan masa (bulanan) PPh Pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng Jalan Sumatera No. 22-24. Surat pemberian ijin pengambilan data diperoleh dari Kantor Wilayah DJP JATIM 1 yang terlampir pada Lampiran 60. Dari 60 data yang ada terdiri dari 48 data *in sample* dan 12 data *out sample*. Struktur data penerimaan pajak ditampilkan pada Tabel 3.1.

Tabel 3.1 Struktur Data Penerimaan Pajak

Tahun	Bulan	Penerimaan Pajak (Rupiah)
2012	Januari	Z_1
	Februari	Z_2

	Desember	Z_{12}
2013	Januari	Z_{13}
	Februari	Z_{14}

	Desember	Z_{24}
2014	Januari	Z_{25}
	Februari	Z_{26}

	Desember	Z_{36}
2015	Januari	Z_{37}
	Februari	Z_{38}

	Desember	Z_{48}
2016	Januari	Z_{49}
	Februari	Z_{50}

	Desember	Z_{60}

3.2 Langkah Analisis

Langkah awal dari penelitian ini adalah menentukan model peramalan yang sesuai dengan data jumlah penerimaan masa (bulanan) PPh pasal 21 yang dianalisis menggunakan metode *time series* dengan tahapan sebagai berikut :

1. Membagi data jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng pada tahun 2012-2016 menjadi dua, yaitu data *in sample* dan data *out sample*.
2. Melakukan identifikasi Model ARIMA (p, d, q) dengan langkah sebagai berikut:
 - a. Melakukan *Time Series* Plot terhadap data *in sample* jumlah penerimaan masa PPh pasal 21.
 - b. Melakukan identifikasi stasioneritas pada data *in sample* menggunakan *box-cox* untuk melihat apakah data sudah stationer dalam varian atau belum.
 - c. Melakukan identifikasi stasioneritas pada data *in sample* melalui plot ACF dan PACF untuk melihat apakah data sudah stationer dalam *mean* atau belum, jika data belum stationer dalam *mean* maka dilakukan *differencing*. Selain itu untuk mengetahui apakah data jumlah penerimaan masa PPh pasal 21 stationer dalam *mean* dapat juga dilihat melalui plot ACF dan PACF data awal, jika pada plot tersebut *lag-lag* turun secara melambat maka data tersebut belum stationer dalam *mean*.
 - d. Membuat plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data *in sample* yang sudah stationer dalam *mean*.
3. Melakukan pendugaan model ARIMA (p, d, q) awal
Melakukan pendugaan model yang terbentuk melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) yang sudah memenuhi syarat stationer.
4. Melakukan uji kelayakan terhadap model ARIMA (p, d, q)

yang didapatkan.

- a. Estimasi parameter dan pengujian signifikansi parameter

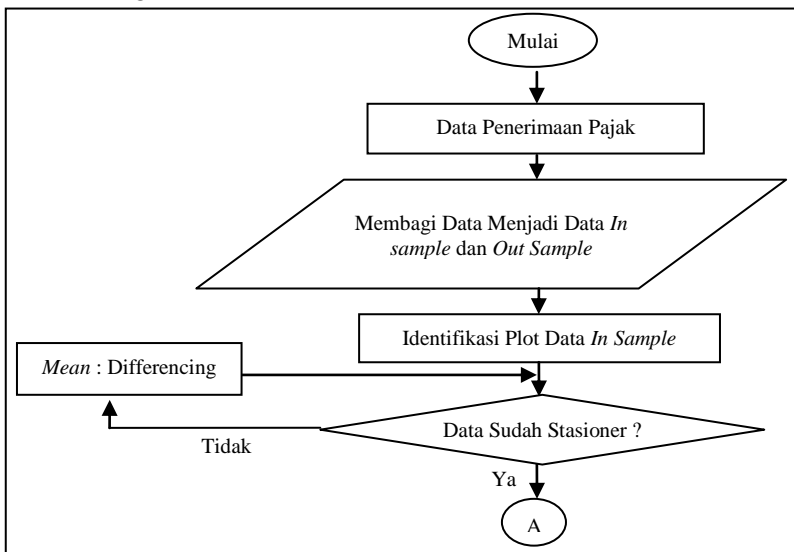
Melakukan penaksiran parameter berdasarkan model sementara yang didapatkan dan melakukan uji signifikansi parameter sampai mendapatkan model yang memiliki parameter signifikan.

- b. *Diagnostic Checking*

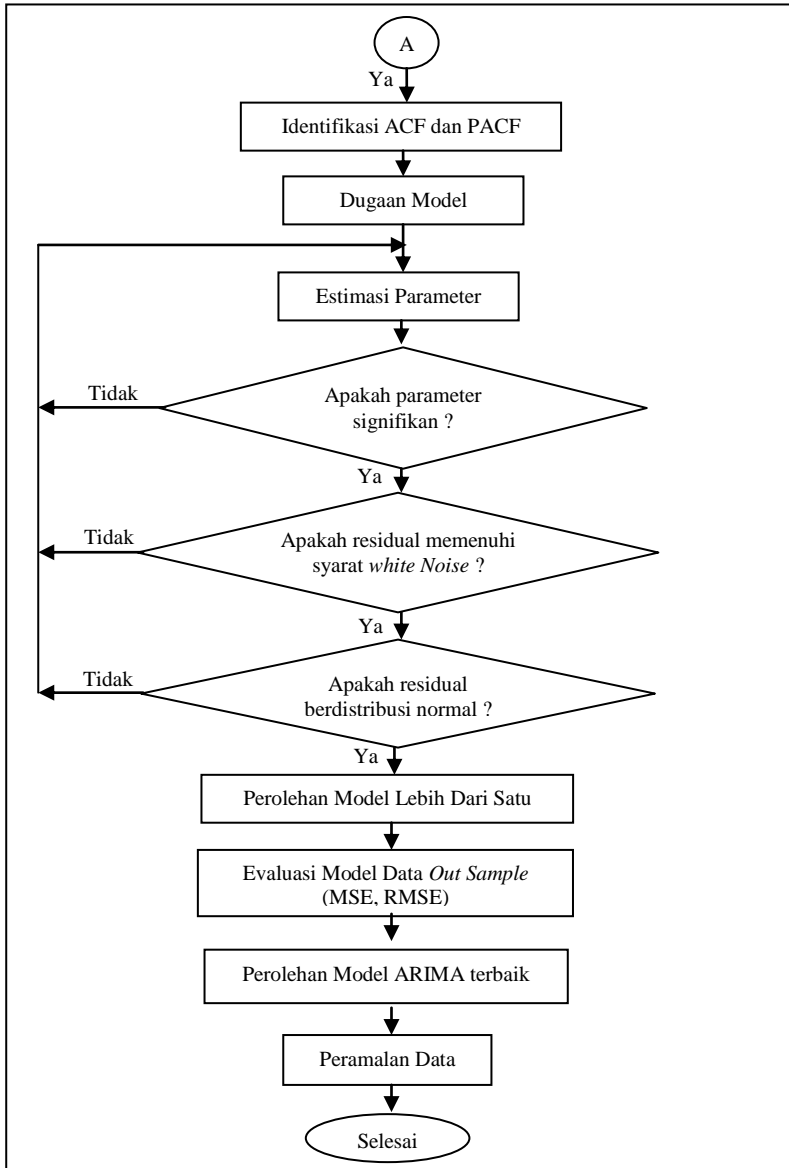
Melakukan *diagnostic checking* melalui pemeriksaan terhadap residual dari model yang signifikan yaitu melalui Uji residual *white noise* dan Uji residual berdistribusi normal

5. Evaluasi terhadap model ARIMA (p, d, q) yang didapatkan jika model yang dihasilkan lebih dari satu melalui dua kriteria. Kriteria *in sample* berdasarkan nilai AIC atau SBC Kriteria *out sample* berdasarkan nilai RMSE atau MAPE.
6. Setelah terpilih satu model terbaik, maka dapat dilakukan peramalan penerimaan masa pajak PPh pasal 21 di KPP Pratama Surabaya Gubeng periode Januari 2017 sampai Desember 2017.

Rangkuman dari langkah analisis dapat dilihat dalam bentuk diagram alir di Gambar 3.1



Gambar 3.1 Diagram Alir

**Gambar 3.1** Diagram Alir (Lanjutan)


BAB IV

ANALISIS DAN PEMBAHASAN

Pada bab ini akan dijelaskan mengenai analisis dan pembahasan peramalan jumlah penerimaan masa (bulanan) PPh pasal 21 di Kantor Pelayanan Pajak (KPP) Pratama Surabaya Gubeng. Pembahasan diawali dari bagaimana pemodelan ARIMA yang terdiri dari identifikasi model, pengujian model dan bagaimana peramalan penerimaan pajak untuk periode Januari sampai Desember tahun 2017.

4.1 Pemodelan Penerimaan Masa PPh Pasal 21

Pemodelan penerimaan masa (bulanan) PPh pasal 21 di KPP Pratama Surabaya Gubeng digunakan untuk menentukan model terbaik. Model terbaik yang didapat akan digunakan untuk melakukan peramalan 12 periode (bulan) ke depan yaitu pada tahun 2017. Berdasarkan data penerimaan di Lampiran 1. di Kantor Pelayanan Pajak (KPP) Pratama Surabaya Gubeng periode Januari 2012 sampai dengan Desember 2016 dapat digambarkan melalui *time series plot* pada Gambar 4.1 berikut.



Gambar 4.1 *Time Series Plot* Penerimaan Masa PPh Pasal 21


Gambar 4.1 menunjukkan bahwa penerimaan masa PPh pasal 21 di KPP Pratama Surabaya Gubeng bulan Januari 2012 sampai dengan bulan Desember 2016 cenderung tidak stabil. Setiap bulan kelipatan ke dua belas (bulan Desember) terlihat

jumlah penerimaannya selalu lebih tinggi dibandingkan bulan-bulan sebelumnya, Kenaikan yang ekstrim yang umumnya ternyadi pada bulan Desember dikarenakan perusahaan atau pemerintahan sebagai pemotong pajak mempunyai sistem pembukuan di akhir Desember saldo kas nihil atau nol, pajak masa (bulan) November dibayar di masa Desember dan pajak masa Desember yang seharusnya bisa dilaporkan pada Januari tahun berikutnya dilaporkan pada bulan Desember saat itu juga agar kas menjadi nihil.

Pada analisis ini dari 60 data yang ada dibagi menjadi data *in sample* (data penerimaan pada bulan Januari tahun 2012 sampai dengan bulan Desember 2015) dan data *out sample* (yaitu data penerimaan pada bulan Januari tahun 2016 sampai dengan bulan Desember 2016). Data *in sample* digunakan untuk meramalkan data *out sample*. Berikut tahapan pemodelan menggunakan ARIMA *Box-Jenkins*.


4.1.1 Identifikasi Model Penerimaan Masa PPh Pasal 21

Langkah pertama yang dilakukan adalah membuat *time series plot* data *in sample* jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng yaitu bulan Januari tahun 2012 sampai dengan bulan Desember 2015 untuk mengidentifikasi model penerimaan masa PPh pasal 21.



Gambar 4.2 Time Series Plot Penerimaan Masa PPh Pasal 21 Data In Sample


Gambar 4.2 menunjukkan penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng bulan Januari 2012 sampai dengan bulan Desember 2015 cenderung tidak stabil. Selanjutnya dilakukan pemeriksaan apakah data telah stasioner dalam varians dan mean atau tidak. Berikut pemeriksaan kestasioneran data dalam varians menggunakan *Box-Cox Transformation*.



Gambar 4.3 Plot *Box-Cox* Penerimaan Masa PPh Pasal 21


Gambar 4.3 menunjukkan bahwa dari hasil pengujian penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng belum stasioner dalam *variens*. Hasil pemeriksaan menggunakan menggunakan *box-cox* nilai *rounded value* yang diperoleh sebesar -0,50 dan selang interval data antara -1,35 dan 0,38 sehingga belum melewati angka 1. Pada tugas akhir ini tidak dilakukan transformasi pada data penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng, karena hasil transformasi yang diperoleh tidak umum digunakan dan dikhawatirkan akan menghilangkan informasi yang ada pada data penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng yang dapat dilihat di Lampiran 59. Selanjutnya dilanjutkan pemeriksaan stasioner dalam *mean* pada data penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dengan pemeriksaan stasioner dalam *mean* menggunakan plot ACF. Pemeriksaan

secara visual menggunakan plot ACF data penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dapat dilihat pada Gambar 4.4.




Gambar 4.4 Plot ACF Penerimaan Masa PPh Pasal 21

Hasil analisis secara visual menggunakan plot ACF pada Gambar 4.4 menunjukkan bahwa data belum stasioner dalam *mean*. Hal tersebut terlihat dari beberapa plot ACF yang turun lambat atau *diesdown*. Selain itu, pada Gambar 4.2 terlihat plot data tidak berfluktuasi konstan di sekitar garis sejajar. Oleh karena itu, perlu dilakukan *differencing* untuk mengatasi ketidakstasioneran dalam *mean*.




Gambar 4.5 Time Series Plot Penerimaan Masa PPh Pasal 21 Hasil Differencing

Gambar 4.5 menunjukkan bahwa plot data *in sample* penerimaan masa PPh pasal 21 sudah berfluktuasi konstan atau mengikuti garis *mean*. Sehingga dapat disimpulkan bahwa data telah stasioner dalam *mean*. Setelah mengetahui bahwa data telah stasioner, langkah selanjutnya adalah identifikasi model dengan melihat plot ACF dan PACF yang ditunjukkan pada Gambar 4.6.



(a)



(b)

Gambar 4.6 (a) Plot ACF dan (b) Plot PACF
Data Penerimaan Masa PPh Pasal 21

Gambar 4.6 menunjukkan plot ACF dan PACF yang digunakan untuk mengidentifikasi model ARIMA *box-jenkins*. Pada plot ACF terlihat bahwa plot ACF cut off setelah lag 1 dan 12 karena memiliki nilai autokorelasi yang besar 12 serta tidak membentuk pola musiman dengan hasil selengkapnya dapat dilihat pada Lampiran 2. Sedangkan pada plot PACF terlihat bahwa plot PACF cut off setelah lag 2 dan 11 yang memiliki nilai autokorelasi parsial terbesar yang dapat dilihat pada Lampiran 3. Plot ACF digunakan untuk membentuk model yaitu sebagai orde q atau orde pada model *moving average* pada model ARIMA (p,d,q) . Sedangkan plot PACF digunakan untuk mengidentifikasi model yaitu sebagai orde p atau orde pada model *autoregressive* pada model ARIMA (p,d,q) . Sedangkan orde d merupakan orde dari proses *differencing* akibat data tidak stasioner dalam *mean*. Sebagai contoh pada Gambar 4.6 plot ACF yang signifikan pada lag 1, model dugaan yang dapat diidentifikasi adalah ARIMA $(0,1,1)$, sedangkan pada plot PACF yang signifikan pada lag 1, didapatkan model dugaan ARIMA $(1,1,0)$. Untuk model *subset* misalnya pada plot ACF cut off pada lag 1 dan 12, maka model dugaannya adalah ARIMA $(0,1,[1,12])$, sedangkan pada plot PACF cut off pada lag 1, 2, dan 11 maka model dugaan yang terbentuk adalah ARIMA $([1,2,11],1,0)$.

4.1.2 Estimasi Parameter Penerimaan Masa PPh Pasal 21

Estimasi parameter digunakan untuk melihat apakah parameter-parameter dari model dugaan ARIMA telah signifikan atau tidak. Berdasarkan 24 dugaan model yang ada pada Lampiran 4, hasil estimasi parameter dari model dugaan data jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dapat dilihat pada Tabel 4.1.

Berdasarkan Tabel 4.1 dapat diketahui bahwa dari penduga model ARIMA yang telah dilakukan pengujian, model yang memiliki parameter signifikan adalah model ARIMA yang terdapat pada Tabel 4.1 diatas karena nilai mutlak statistik uji t lebih besar dari $t_{0,005;46}$ (2,687) dan nilai *P-value* yang kurang dari taraf signifikan α sebesar 0,01. Setelah mengetahui

model ARIMA yang memiliki parameter signifikan, selanjutnya dilakukan pemeriksaan asumsi residual.

Tabel 4.1 Hasil Pemodelan ARIMA

Model ke-	Model ARIMA	Parameter	Lag	Estimasi	<i>St. Error</i>	t	<i>P-value</i>
1	(0,1,1)	θ_1	1	0,85503	0,08984	9,52	< 0,0001*
2	(0,1,[12])	θ_{12}	12	-0,49301	0,16579	-0,297	0,0047*
3	(1,1,0)	ϕ_1	1	-0,40386	0,14495	-0,79	0,0077*
9	(1,1,[12])	θ_{12}	12	-0,54823	0,16665	-3,29	0,0020*
		ϕ_1	1	-0,46219	0,13918	-3,32	0,0018*
12	(0,1,[1,12])	θ_1	1	0,49476	0,14557	3,40	0,0014*
		θ_{12}	12	-0,3324	0,18722	-2,85	0,0066*
13	([1,2,11],1,0)	ϕ_1	1	-0,61329	0,13416	-4,57	< 0,0001*
		ϕ_2	2	-0,47533	0,13447	-3,53	0,0010*
		ϕ_{11}	11	-0,42061	0,15199	-2,77	0,0082*
		θ_{12}	12	-0,56630	0,15892	-3,56	0,0009*
18	([1,2],1,12)	ϕ_1	1	-0,65542	0,14103	-4,65	< 0,0001*
		ϕ_2	2	-0,44735	0,14108	-3,17	0,0028*

Keterangan. *: Signifikan

Berdasarkan hasil pengolahan *syntax* Lampiran 5 sampai 28 sehingga didapat hasil output pada Lampiran 29 sampai 52 diperoleh hasil pada Tabel 4.1 dapat diketahui bahwa dari penduga model ARIMA yang telah dilakukan pengujian, model yang memiliki parameter signifikan adalah model ARIMA yang terdapat pada Tabel 4.1 diatas karena nilai mutlak statistik uji t lebih besar dari $t_{0,005;46}$ (2,687) dan nilai *P-value* yang kurang dari taraf signifikan α sebesar 0,01. Setelah mengetahui model ARIMA yang memiliki parameter signifikan, selanjutnya dilakukan pemeriksaan asumsi residual.

4.1.3 Pemeriksaan Residual Penerimaan Masa PPh Pasal 21

Pemeriksaan residual data jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dilakukan untuk menganalisis apakah model dugaan telah memenuhi asumsi residual white noise dan residual berdistribusi normal.

a. Uji Asumsi Residual *White Noise*

Hasil pengujian asumsi residual *white noise* model ARIMA (0,1,[12]) dan model ARIMA (0,1,[1,12]) terdapat pada Tabel 4.2.

Tabel 4.2 Hasil Pengujian Residual *White Noise*

Model Ke	Model ARIMA	Lag	χ^2	df	$\chi^2_{(0,01;df)}$	P-value
2	(0,1,[12])	6	11,04	5	15,086	0,0505*
		12	17,74	11	24,725	0,0879*
		18	19,60	17	33,409	0,2950*
		24	36,83	23	41,638	0,0339*
12	(0,1,[1,12])	6	7,24	4	13,27	0,1236*
		12	16,27	10	23,21	0,0923*
		18	19,20	16	31,99	0,2583*
		24	36,98	22	40,29	0,0238*

Keterangan. *:Signifikan

Tabel 4.2 menunjukkan hasil pengujian asumsi residual *white noise* pada model ARIMA (0,1,[12]) dan model ARIMA (0,1,[1,12]) memiliki nilai statistik uji χ^2 pada model ARIMA di atas lebih kecil dari $\chi^2_{(0,01;df)}$ dan nilai *P-value* lebih besar dari α sebesar 0,01 sehingga diperoleh keputusan H_0 gagal ditolak yang artinya sudah memenuhi asumsi residual *white noise*.

b. Uji Asumsi Residual Distribusi Normal

Pengujian untuk memeriksa apakah berdistribusi normal atau tidak dapat dilakukan dengan menggunakan uji Kolmogorov Smirnov. Tabel 4.3 menunjukkan hasil pengujian residual berdistribusi normal dengan menggunakan Uji Kolmogorov Smirnov. Berdasarkan hasil pengujian, model ARIMA (0,1,[12])

dan ARIMA (0,1,[1,12]) telah memenuhi asumsi residual berdistribusi normal karena nilai statistik uji Kolmogorov Smirnov yang kurang dari $D_{0,99;48}$ (0,2353) dan nilai *P-value* lebih dari α sebesar 0,01 yang terlampir pada Lampiran 30 dan 40.

Tabel 4.3 Hasil Pengujian Residual Berdistribusi Normal

Model Ke-	Model ARIMA	Kolmogorov Smirnov	<i>P-Value</i>	Keterangan
2	(0,1,[12])	0,090932	> 0,1500	Berdistribusi Normal
12	(0,1,[1,12])	0,110496	> 0,1500	Berdistribusi Normal

4.1.4 Pemilihan Model Terbaik Penerimaan Masa PPh 21

Model penduga yang didapatkan lebih dari satu, maka selanjutnya dilakukan perhitungan kriteria model terbaik dari data *in sample* dan data *out sample* jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng. Kriteria pemilihan model terbaik disajikan pada Tabel 4.4.

Tabel 4.4 Kriteria Pemilihan Model Terbaik

Model	<i>In Sample</i>		<i>Out Sample</i>	
	AIC	SBC	RMSE	MAPE
ARIMA (0,1,12)	2.231,811	2.233,661	4.450.010.323	0,2411
ARIMA (0,1,[1,12])	2.216,571	2.220,271	4.946.646.857	0,3029

Tabel 4.4 menunjukkan hasil perhitungan kriteria pemilihan model terbaik. Perhitungan nilai RMSE dan MAPE dapat dilihat di Lampiran 53 dan 54. Berdasarkan kriteria *in sample* yaitu AIC dan SBC menunjukkan model terbaik adalah model ARIMA (0,1,[1,12]), sedangkan untuk kriteria *out sample* yaitu RMSE dan MAPE menunjukkan model terbaik adalah model ARIMA (0,1,[12]). Kriteria *in sample* hanya digunakan untuk melihat secara umum akurasi model yang telah didapatkan, sedangkan untuk pemilihan model terbaik untuk peramalan digunakan kriteria *out sample* yaitu untuk menguji apakah akurasi model tersebut benar meskipun digunakan diluar data pembentuk

model. Oleh karena itu, dapat disimpulkan bahwa model terbaik untuk penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng adalah model ARIMA (0,1,[12]).

Bentuk umum model ARIMA (0,1,[12]) adalah sebagai berikut.

$$\begin{aligned}(1-B)^1 \dot{Z}_t &= (1-\theta_{12}B^{12})a_t \\ \dot{Z}_t - \dot{Z}_{t-1} &= a_t - \theta_{12}a_{t-12} \\ Z_t - \mu &= (Z_{t-1} - \mu) + a_t - \theta_{12}a_{t-12} \\ Z_t &= Z_{t-1} + a_t - \theta_{12}a_{t-12} \\ Z_t &= Z_{t-1} + a_t - (-0,5629)a_{t-12}\end{aligned}$$

Berdasarkan model matematis diketahui bahwa peramalan penerimaan penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dipengaruhi kesalahan peramalan 12 bulan sebelumnya.

4.2 Peramalan Jumlah Penerimaan Masa PPh Pasal 21

Peramalan dilakukan untuk memprediksi data pada beberapa periode ke depan. Peramalan jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dilakukan pada satu tahun ke depan yaitu bulan Januari 2017 sampai dengan Desember 2017. Berdasarkan model terbaik dari data jumlah penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng yaitu model ARIMA (0,1,[12]) diperoleh hasil sebagai berikut.

Tabel 4.5 menunjukkan bahwa total penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng dari hasil peramalan sebanyak Rp 281.891.706.381. Berikut adalah contoh perhitungan untuk ramalan penerimaan PPh pasal 21 pada bulan Januari 2017 ($z_{t=61}$).

$$\begin{aligned}Z_t &= Z_{t-1} + a_t - (-0,5629)a_{t-12} \\ Z_{61} &= Z_{60} + a_{61} - (-0,5629)a_{49}\end{aligned}$$

$$Z_{61} = 2725994779 - (-0,5629)(-9286027818)$$

$$Z_{61} = \text{Rp } 22.032.823091$$

Tabel 4.5 Ramalan Jumlah Penerimaan Tahun 2017

Tahun	Bulan	Ramalan
2017	1	Rp 22.032.855.506
2017	2	Rp 23.761.891.288
2017	3	Rp 21.882.524.680
2017	4	Rp 23.593.683.579
2017	5	Rp 23.229.404.253
2017	6	Rp 25.858.879.362
2017	7	Rp 23.560.220.647
2017	8	Rp 22.184.482.376
2017	9	Rp 22.214.983.737
2017	10	Rp 23.334.630.839
2017	11	Rp 22.530.771.953
2017	12	Rp 27.707.378.161
Total		Rp 281.891.706.381

Peramalan penerimaan tahun 2017 tersebut dapat digunakan untuk menentukan target penerimaan tahun 2018 jika modelnya tetap.

Halaman ini sengaja dikosongkan

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, didapat kesimpulan sebagai berikut.

1. Model terbaik dari penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng adalah ARIMA (0,1,[12]) yang artinya peramalan jumlah penerimaan dipengaruhi oleh residual peramalan pada 12 bulan sebelumnya.
2. Berdasarkan model ARIMA (0,1,[12]) hasil peramalan untuk total penerimaan masa PPh pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng bulan Januari sampai Desember tahun 2017 adalah sebesar Rp 281.891.706.381, dengan jumlah penerimaanya paling tinggi terjadi pada bulan Desember 2017 dan yang paling rendah terjadi pada bulan Maret 2017.

5.2 Saran

Saran setelah mengetahui prediksi jumlah penerimaan masa (bulanan) PPh pasal 21 adalah sebagai berikut.

1. Dilakukan sosialisasi kepada wajib pajak agar dapat memenuhi kewajiban perpajakannya, dan tidak adanya kesalahan khususnya dalam pelaporan SPT.
2. Jika model tetap, hasil perhitungan target sebesar Rp 332.488.155.371 dapat digunakan oleh Kantor Pelayanan Pajak Pratama Surabaya Gubeng sebagai target penerimaan tahun 2018 yang dapat dilihat pada Lampiran 58.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Box, G., Jenkins, G., & Reinsel, G. (2008). *Time Series Analysis : Forecasting and Control* (4 ed.). Wiley.
- Cryer, J., & Chan, K. (2008). *Time Series Analysis With Applications in R* (2 ed.). New York: Springer.
- Daniel, W. (1989). *Statistika Nonparametrik Terapan*. Jakarta: PT. Gramedia.
- Direktorat Jenderal Pajak. (2016). Retrieved November 28, 2016, from SPT Masa PPh Pasal 21: www.pajak.go.id
- Judisseno, R. K. (1997). *Pajak dan Strategi Bisnis*. Jakarta: Gramedia Pustaka Umum.
- Makridakis, S., Wheelwright, S., & McGee, V. (1999). *Metode dan Aplikasi Peramalan* (2 ed.). (Ir. H. Suminto, Trans.) Jakarta: Bina Rupa Aksara.
- Mardiasmo. (2003). *Perpajakan Edisi Revisi*. Yogyakarta: Penerbit Andi.
- Wei, W. (2006). *Time Series Analysis Univariate and Mutivariate Methods* (2 ed.). New York: Pearson Education.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1. Data Penerimaan Masa PPh Pasal 21 di Kantor Pelayanan Pajak Pratama Surabaya Gubeng

Bulan	Tahun		
	2012	2013	2014
Januari	Rp 10.457.671.125	Rp 11.067.561.827	Rp 13.854.394.653
Februari	Rp 6.986.366.081	Rp 6.846.229.020	Rp 7.718.064.571
Maret	Rp 8.879.130.404	Rp 7.973.456.803	Rp 11.355.209.809
April	Rp 9.958.241.751	Rp 9.901.054.227	Rp 13.701.134.749
Mei	Rp 8.633.575.373	Rp 10.593.028.182	Rp 13.489.707.650
Juni	Rp 12.573.095.215	Rp 11.194.638.401	Rp 10.681.046.882
Juli	Rp 9.217.094.399	Rp 15.757.140.640	Rp 19.325.252.655
Agustus	Rp 16.062.967.963	Rp 10.071.054.097	Rp 16.180.374.082
September	Rp 10.738.458.875	Rp 11.757.565.097	Rp 13.610.582.031
Oktober	Rp 9.195.280.340	Rp 12.626.507.253	Rp 15.379.088.179
Nopember	Rp 10.686.511.340	Rp 11.540.930.140	Rp 14.312.312.499
Desember	Rp 21.201.043.113	Rp 21.203.218.842	Rp 24.522.456.422

**Lampiran 1. Data Penerimaan Masa PPh Pasal 21 di
Kantor Pelayanan Pajak Pratama Surabaya
Gubeng (Lanjutan).**

Bulan	Tahun	
	2015	2016
Januari	Rp 17.595.252.608	Rp 14.463.985.218
Februari	Rp 9.390.193.624	Rp 14.456.980.630
Maret	Rp 14.293.935.146	Rp 12.737.120.307
April	Rp 15.582.440.728	Rp 15.994.479.897
Mei	Rp 13.773.002.175	Rp 14.652.200.600
Juni	Rp 13.585.808.104	Rp 19.819.880.655
Juli	Rp 25.651.157.836	Rp 20.939.533.205
Agustus	Rp 15.532.280.465	Rp 12.094.643.213
September	Rp 12.478.672.289	Rp 12.079.563.911
Oktober	Rp 18.859.473.844	Rp 17.409.929.381
Nopember	Rp 14.171.382.712	Rp 13.337.622.815
Desember	Rp 27.128.212.237	Rp 27.259.947.795

Lampiran 2. *Output* Minitab ACF

```
MTB > ACF 'Differencing';
SUBC>    Lags 48;
```

Autocorrelation Function: Insample

Lag	ACF	T	LBQ
1	0,201758	1,40	2,08
2	0,067127	0,45	2,31
3	0,174485	1,16	3,94
4	0,204963	1,32	6,23
5	0,239302	1,49	9,43
6	0,089085	0,53	9,88
7	0,229018	1,36	12,95
8	0,094205	0,54	13,48
9	0,056511	0,32	13,68
10	-0,039277	-0,22	13,78
11	0,153806	0,87	15,31
12	0,540348	3,01	34,77
13	0,101174	0,48	35,48
14	-0,061802	-0,29	35,75
15	0,042519	0,20	35,88
16	0,039431	0,19	35,99
17	-0,022790	-0,11	36,03
18	-0,090050	-0,42	36,68
19	0,074122	0,35	37,14
20	-0,077967	-0,36	37,66
21	-0,136462	-0,64	39,31
22	-0,177019	-0,82	42,21
23	-0,055528	-0,25	42,50
24	0,221637	1,01	47,42
25	-0,043372	-0,19	47,61
26	-0,188135	-0,84	51,47
27	-0,121465	-0,53	53,16
28	-0,101618	-0,44	54,40
29	-0,153458	-0,67	57,37
30	-0,178844	-0,77	61,64
31	-0,039999	-0,17	61,86
32	-0,168495	-0,72	66,12
33	-0,215799	-0,91	73,57

Lampiran 2. Output Minitab ACF (Lanjutan)

34	-0,169071	-0,70	78,47
35	-0,065115	-0,27	79,26
36	0,036539	0,15	79,52
37	-0,079241	-0,32	80,89
38	-0,116366	-0,48	84,14
39	-0,114765	-0,47	87,66
40	-0,031337	-0,13	87,95
41	-0,163778	-0,66	97,15
42	-0,077212	-0,31	99,53
43	-0,089523	-0,36	103,38
44	-0,080031	-0,32	107,22
45	-0,080428	-0,32	112,40
46	-0,087329	-0,35	121,55
47	-0,039752	-0,16	125,34

Lampiran 3. *Output* Minitab PACF

```
MTB > PACF 'Differencing';
SUBC>     Lags 48;
```

Partial Autocorrelation Function: differencing

Lag	PACF	T
1	-0,360823	-2,47
2	-0,396916	-2,72
3	-0,185207	-1,27
4	-0,199864	-1,37
5	-0,072660	-0,50
6	-0,203368	-1,39
7	0,124895	0,86
8	0,001194	0,01
9	0,206965	1,42
10	-0,128869	-0,88
11	-0,404354	-2,77
12	0,130849	0,90
13	0,150007	1,03
14	-0,018059	-0,12
15	0,000770	0,01
16	-0,032211	-0,22
17	0,039484	0,27
18	0,029451	0,20
19	0,020362	0,14
20	-0,045856	-0,31
21	0,019497	0,13
22	-0,009741	-0,07
23	-0,075010	-0,51
24	-0,034016	-0,23
25	0,033665	0,23
26	0,014646	0,10
27	0,014627	0,10
28	0,023316	0,16
29	-0,015827	-0,11
30	-0,003401	-0,02
31	0,058909	0,40
32	-0,002389	-0,02
33	-0,054187	-0,37

Lampiran 3. *Output* Minitab PACF (Lanjutan)

34	-0,073239	-0,50
35	0,098031	0,67
36	-0,090554	-0,62
37	-0,120533	-0,83
38	-0,013706	-0,09
39	-0,075700	-0,52
40	0,000492	0,00
41	-0,061845	-0,42
42	0,137097	0,94
43	-0,074936	-0,51
44	-0,061035	-0,42
45	-0,013316	-0,09
46	0,045219	0,31

Lampiran 4. Model ARIMA yang terbentuk

Model Ke-	Model ARIMA	Parameter	Lag	t	P-value
1	(0,1,1)	θ_1	1	9,52	< 0,0001
2	(0,1,[12])	θ_{12}	12	-2,97	0,0047
3	(1,1,0)	ϕ_1	1	-2,79	0,0077
4	([2],1,0)	ϕ_2	2	-1,58	0,1211
5	([11],1,0)	ϕ_{11}	11	-1,73	0,0895
6	(1,1,1)	θ_1	1	7,96	< 0,0001
		ϕ_1	1	-0,19	0,8486
7	([2],1,1)	θ_1	1	7,68	< 0,0001
		ϕ_2	2	-1,51	0,1390
8	([11],1,1)	θ_1	1	10,17	< 0,0001
		ϕ_{11}	11	0,66	0,5107
9	(1,1,[12])	θ_{12}	12	-3,29	0,0020
		ϕ_1	1	-3,32	0,0018
10	([2],1,[12])	θ_{12}	12	-2,86	0,0064
		ϕ_2	2	-1,15	0,2578
11	([11],1,[12])	θ_{12}	12	-2,47	0,0175
		ϕ_{11}	11	-0,19	0,8497
12	(0,1,[1,12])	θ_1	1	3,40	0,0014
		θ_{12}	12	-2,85	0,0066
13	([1,2,11],1,0)	ϕ_1	1	-4,57	< 0,0001
		ϕ_2	2	-3,53	0,0010
		ϕ_{11}	11	-2,77	0,0082

Lampiran 4. Model ARIMA yang terbentuk (Lanjutan)

Model Ke-	Model ARIMA	Parameter	Lag	t	P-value
14	(1,1,[1,12])	θ_1	1	1,63	0,1105
		θ_{12}	12	-1,92	0,0610
		ϕ_1	1	0,91	0,3697
15	([2],1,[1,12])	θ_1	1	3,51	0,0010
		θ_{12}	12	-2,76	0,0084
		ϕ_2	2	-0,94	0,3525
16	([11],1,[1,12])	θ_1	1	3,34	0,0017
		θ_{12}	12	-2,66	0,0109
		ϕ_{11}	11	0,31	0,7563
17	([1,2],1,1)	θ_1	1	6,13	< 0,0001
		ϕ_1	1	-0,45	0,6537
		ϕ_2	2	-1,51	0,1389
18	([1,2],1,[12])	θ_{12}	12	-3,56	0,0009
		ϕ_1	1	-4,65	< 0,0001
		ϕ_2	2	-3,17	0,0028
19	([1,11],1,1)	θ_1	1	8,57	< 0,0001
		ϕ_1	1	-0,02	0,9864
		ϕ_{11}	11	0,64	0,5272
20	([1,11],1,[12])	θ_{12}	12	-2,56	0,0139
		ϕ_1	1	-3,28	0,0020
		ϕ_{11}	11	-0,19	0,8478
21	([2,11],1,1)	θ_1	1	7,82	< 0,0001
		ϕ_2	2	-1,42	0,1620
		ϕ_{11}	11	0,23	0,8214

Lampiran 4. Model ARIMA yang terbentuk (Lanjutan)

Model Ke-	Model ARIMA	Parameter	Lag	t	P-Value
22	([2,11],1,[12])	θ_{12}	12	-2,31	0,0256
		ϕ_2	2	-1,16	0,2518
		ϕ_{11}	11	-0,30	0,7636
23	([1,2,11],1,1)	θ_1	1	6,05	< 0,0001
		ϕ_1	1	-0,44	0,6647
		ϕ_2	2	-1,47	0,1488
		ϕ_{11}	11	0,01	0,9917
24	([1,2,11],1,[12])	θ_{12}	1	-2,44	0,0187
		ϕ_1	1	-4,57	< 0,0001
		ϕ_2	2	-3,14	0,0031
		ϕ_{11}	11	-0,31	0,7605

Lampiran 5. Syntax SAS Model ARIMA (0,1,1)

```
data pajak1;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak1 out=out1;
identify var=y(1);
run;
estimate p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```


Lampiran 6. Syntax SAS Model ARIMA (0,1,[12])

```
data pajak2;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak2 out=out1;
identify var=y(1);
run;
estimate p=(0) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 7. Syntax SAS Model ARIMA (1,1,0)

```
data pajak3;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak3 out=out1;
identify var=y(1);
run;
estimate p=(1) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 8. Syntax SAS Model ARIMA ([2],1,0)

```
data pajak4;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak4 out=out1;
identify var=y(1);
run;
estimate p=(2) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 9. Syntax SAS Model ARIMA ([11],1,0)

```
data pajak5;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak5 out=out1;
identify var=y(1);
run;
estimate p=(11) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 10. Syntax SAS Model ARIMA (1,1,1)

```
data pajak6;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak6 out=out1;
identify var=y(1);
run;
estimate p=(1) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 11. Syntax SAS ARIMA ([2],1,1)

```
data pajak7;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak7 out=out1;
identify var=y(1);
run;
estimate p=(2) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 12. Syntax SAS Model ARIMA ([11],1,1)

```
data pajak8;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak8 out=out1;
identify var=y(1);
run;
estimate p=(11) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 13. Syntax SAS Model ARIMA (1,1,[12])

```
data pajak9;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak9 out=out1;
identify var=y(1);
run;
estimate p=(1) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```


Lampiran 14. Syntax SAS Model ARIMA ([2],1,[12])

```
data pajak10;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak10 out=out1;
identify var=y(1);
run;
estimate p=(2) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 15. Syntax SAS Model ARIMA ([11],1,[12])

```
data pajak11;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak11 out=out1;
identify var=y(1);
run;
estimate p=(11) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 16. Syntax SAS Model ARIMA (0,1,[1,12])

```
data pajak12;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak12 out=out1;
identify var=y(1);
run;
estimate p=(0) q=(1,12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 17. Syntax SAS Model ARIMA ([1,2,11],1,0)

```
data pajak13;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak13 out=out1;
identify var=y(1);
run;
estimate p=(1,2,11) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 18. Syntax SAS Model ARIMA (1,1,[1,12])

```
data pajak14;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak14 out=out1;
identify var=y(1);
run;
estimate p=(1) q=(1,12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 19. Syntax SAS Model ARIMA ([2],1,[1,12])

```
data pajak15;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak15 out=out1;
identify var=y(1);
run;
estimate p=(2) q=(1,12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 20. Syntax SAS Model ARIMA ([11],1,[1,12])

```
data pajak16;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak16 out=out1;
identify var=y(1);
run;
estimate p=(11) q=(1,2)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 21. Syntax SAS Model ARIMA ([1,2],1,1)

```
data pajak17;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak17 out=out1;
identify var=y(1);
run;
estimate p=(1,2) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```


Lampiran 22. Syntax SAS Model ARIMA ([1,2],1,[12])

```
data pajak18;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak18 out=out1;
identify var=y(1);
run;
estimate p=(1,2) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 23. Syntax SAS Model ARIMA ([1,11],1,1)

```
data pajak19;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak19 out=out1;
identify var=y(1);
run;
estimate p=(1,11) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 24. Syntax SAS Model ARIMA ([1,11],1,[12])

```

data pajak20;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak20 out=out1;
identify var=y(1);
run;
estimate p=(1,11) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;

```

Lampiran 25. Syntax SAS Model ARIMA ([2,11],1,1)

```
data pajak21;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak21 out=out1;
identify var=y(1);
run;
estimate p=(2,11) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 26. Syntax SAS Model ARIMA ([2,11],1,[12])

```

data pajak22;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak22 out=out1;
identify var=y(1);
run;
estimate p=(2,11) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;

```

Lampiran 27. Syntax SAS Model ARIMA ([1,2,11],1,1)

```
data pajak23;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak23 out=out1;
identify var=y(1);
run;
estimate p=(1,2,11) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 28. Syntax SAS Model ARIMA ([1,2,11],1,[12])

```

data pajak24;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
15532280465
12478672289
18859473844
14171382712
27128212237
;
proc arima data=pajak24 out=out1;
identify var=y(1);
run;
estimate p=(1,2,11) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;

```

Lampiran 29. Output SAS Pengujian Model ARIMA (0,1,1)

Conditional Least Squares Estimation									
Parameter	Estimate	Error	Standard t Value	Pr > t	Approx Lag				
MA1,1	0.85503	0.08984	9.52	<.0001	1				
Variance Estimate				1.906E19					
Std Error Estimate				4.3657E9					
AIC				2220.891					
SBC				2222.742					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.67	5	0.7513	-0.027	-0.188	-0.002	0.040	0.109	-0.038
12	29.48	11	0.0019	0.167	-0.031	-0.065	-0.181	0.067	0.586
18	31.50	17	0.0174	0.051	-0.136	0.046	0.062	0.009	-0.037
24	50.65	23	0.0008	0.173	-0.013	-0.076	-0.131	0.020	0.381
Tests for Normality									
Test			--Statistic--		-----p Value-----				
Shapiro-Wilk			W	0.88099	Pr < W	0.0002			
Kolmogorov-Smirnov			D	0.182531	Pr > D	<0.0100			
Cramer-von Mises			W-Sq	0.404068	Pr > W-Sq	<0.0050			
Anderson-Darling			A-Sq	2.257545	Pr > A-Sq	<0.0050			

Lampiran 30. Output SAS Pengujian Model ARIMA (0,1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr > t	Approx Lag			
MA1,1	-0.49301		0.16579	-2.97	0.0047	12			
Variance Estimate					2.404E19				
Std Error Estimate					4.9035E9				
AIC					2231.811				
SBC					2233.661				
Number of Residuals					47				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.04	5	0.0505	-0.422	-0.158	0.104	0.005	-0.006	-0.069
12	17.74	11	0.0879	0.207	-0.152	0.044	-0.107	-0.019	0.175
18	19.60	17	0.2950	-0.008	-0.132	0.089	-0.024	-0.013	-0.018
24	36.83	23	0.0339	0.078	-0.016	0.036	-0.079	-0.179	0.360
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.985562	Pr < W	0.8227				
Kolmogorov-Smirnov		D	0.090932	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.034611	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.220031	Pr > A-Sq	>0.2500				
Forecasts for variable y									
Obs	Forecast	Std Error	95% Confidence Limits						
49	24284901396	4.90347E9	14674273376	33895529415					
50	21430433076	6.93456E9	7838952588	35021913564					
51	22987247287	8.49306E9	6341151264	39633343309					
52	23219528601	9.80694E9	3998272562	42440784640					
53	22540022419	1.0964E10	1050004861	44030039978					
54	22969761938	1.2011E10	-571372818	46510896693					
55	27562073150	1.2973E10	2134741467	52989404832					
56	22251896072	1.3869E10	-4931064904	49434857048					
57	21887714671	1.471E10	-6944169387	50719598730					
58	24798978801	1.5506E10	-5592495485	55190453087					
59	22528788853	1.6263E10	-9346058287	54403635994					
60	26971651330	1.6986E10	-6320540715	60263843375					

Lampiran 31. Output SAS Pengujian Model ARIMA (1,1,0)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
AR1,1	-0.40386		0.14495	-2.79	0.0077	1			
	Variance Estimate			2.722E19					
	Std Error Estimate			5.2175E9					
	AIC			2237.647					
	SBC			2239.497					
	Number of Residuals			47					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.67	5	0.0853	-0.160	-0.393	0.021	0.060	0.019	-0.068
12	37.24	11	0.0001	0.193	-0.005	-0.065	-0.286	-0.053	0.550
18	43.69	17	0.0004	-0.047	-0.273	0.044	0.077	-0.061	-0.056
24	63.14	23	<.0001	0.200	0.002	-0.071	-0.183	-0.060	0.350
Tests for Normality									
Test		--Statistic--			-----p Value-----				
Shapiro-Wilk		W	0.971045	Pr < W	0.2902				
Kolmogorov-Smirnov		D	0.113134	Pr > D	0.1347				
Cramer-von Mises		W-Sq	0.084451	Pr > W-Sq	0.1832				
Anderson-Darling		A-Sq	0.523971	Pr > A-Sq	0.1809				

Lampiran 32. Output SAS Pengujian Model ARIMA ([2],1,0)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
AR1,1	-0.24313		0.15393	-1.58	0.1211	2			
	Variance Estimate			3.018E19					
	Std Error Estimate			5.4936E9					
	AIC			2242.494					
	SBC			2244.344					
	Number of Residuals			47					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.68	5	0.0266	-0.447	-0.026	0.065	-0.127	0.125	-0.113
12	36.63	11	0.0001	0.230	-0.175	0.061	-0.067	-0.242	0.475
18	39.79	17	0.0014	-0.122	-0.113	0.078	-0.051	0.043	-0.079
24	54.25	23	0.0002	0.184	-0.107	0.021	-0.033	-0.172	0.278
Tests for Normality									
Test		--Statistic--		----p Value----					
Shapiro-Wilk		W	0.956585	Pr < W	0.0787				
Kolmogorov-Smirnov		D	0.153311	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.161947	Pr > W-Sq	0.0172				
Anderson-Darling		A-Sq	0.873545	Pr > A-Sq	0.0236				

Lampiran 33. Output SAS Pengujian Model ARIMA ([11],1,0)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
AR1,1	-0.31969		0.18428	-1.73	0.0895	11			
Variance Estimate				2.986E19					
Std Error Estimate				5.4647E9					
AIC				2241.998					
SBC				2243.848					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.52	5	0.1298	-0.264	-0.280	0.036	0.067	0.006	-0.111
12	27.54	11	0.0038	0.229	-0.035	-0.030	-0.239	-0.036	0.431
18	32.53	17	0.0129	-0.052	-0.229	0.070	0.058	-0.042	-0.073
24	47.71	23	0.0018	0.176	-0.002	-0.040	-0.138	-0.081	0.317
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.97802	Pr < W	0.5131				
Kolmogorov-Smirnov		D	0.102544	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.058763	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.339824	Pr > A-Sq	>0.2500				

Lampiran 34. Output SAS Pengujian Model ARIMA (1,1,1)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.84985		0.10676	7.96	<.0001	1			
AR1,1	-0.03617		0.18833	-0.19	0.8486	1			
Variance Estimate				1.946E19					
Std Error Estimate				4.4118E9					
AIC				2222.846					
SBC				2226.546					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter		MA1,1		AR1,1					
MA1,1		1.000		0.517					
AR1,1		0.517		1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.72	4	0.6054	-0.007	-0.194	-0.013	0.042	0.106	-0.036
12	30.07	10	0.0008	0.164	-0.030	-0.076	-0.185	0.081	0.589
18	32.11	16	0.0097	0.060	-0.136	0.040	0.062	0.007	-0.035
24	51.74	22	0.0003	0.172	-0.011	-0.083	-0.135	0.030	0.385
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.884252	Pr < W	0.0002				
Kolmogorov-Smirnov		D	0.18746	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.390023	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	2.186035	Pr > A-Sq	<0.0050				

Lampiran 35. Output SAS Pengujian Model ARIMA ([2],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.81589		0.10622	7.68	<.0001	1			
AR1,1	-0.25516		0.16943	-1.51	0.1390	2			
Variance Estimate				1.853E19					
Std Error Estimate				4.3046E9					
AIC				2220.534					
SBC				2224.234					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter		MA1,1		AR1,1					
MA1,1		1.000		0.377					
AR1,1		0.377		1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.76	4	0.7799	-0.071	-0.013	-0.000	-0.061	0.144	-0.054
12	25.98	10	0.0038	0.145	-0.120	-0.033	-0.083	0.036	0.573
18	26.89	16	0.0427	0.062	-0.042	0.049	-0.003	0.050	-0.045
24	43.38	22	0.0042	0.144	-0.068	-0.049	-0.065	0.003	0.371
Tests for Normality									
Test		--Statistic--		----p Value----					
Shapiro-Wilk		W	0.828896	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.201473	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.554635	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	3.132363	Pr > A-Sq	<0.0050				

Lampiran 36. Output SAS Pengujian Model ARIMA ([11],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.87000		0.08556	10.17	<.0001	1			
AR1,1	0.12425		0.18740	0.66	0.5107	11			
Variance Estimate				1.932E19					
Std Error Estimate				4.3954E9					
AIC				2222.496					
SBC				2226.196					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter		MA1,1		AR1,1					
MA1,1		1.000		0.100					
AR1,1		0.100		1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.74	4	0.6016	-0.075	-0.176	0.026	0.025	0.116	-0.038
12	29.12	10	0.0012	0.171	-0.042	-0.035	-0.168	0.016	0.588
18	31.06	16	0.0132	0.024	-0.135	0.055	0.059	0.012	-0.040
24	48.98	22	0.0008	0.183	-0.020	-0.054	-0.118	-0.003	0.369
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.884638	Pr < W	0.0002				
Kolmogorov-Smirnov		D	0.167812	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.346382	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	2.047684	Pr > A-Sq	<0.0050				

Lampiran 37. Output SAS Pengujian Model ARIMA (1,1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	-0.54823		0.16665	-3.29	0.0020	12			
AR1,1	-0.46219		0.13918	-3.32	0.0018	1			
Variance Estimate				1.976E19					
Std Error Estimate				4.4456E9					
AIC				2223.563					
SBC				2227.264					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter		MA1,1		AR1,1					
MA1,1		1.000		0.132					
AR1,1		0.132		1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.21	4	0.0243	-0.193	-0.411	0.048	0.096	-0.019	-0.031
12	18.13	10	0.0529	0.184	-0.094	-0.093	-0.121	0.066	0.203
18	19.78	16	0.2305	-0.018	-0.129	0.048	0.016	-0.060	-0.004
24	41.15	22	0.0079	0.094	0.048	-0.005	-0.208	-0.086	0.397
Tests for Normality									
Test		--Statistic--			----p Value----				
Shapiro-Wilk		W	0.984591	Pr < W	0.7845				
Kolmogorov-Smirnov		D	0.083301	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.036575	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.223966	Pr > A-Sq	>0.2500				

Lampiran 38. *Output* SAS Pengujian Model ARIMA ([2],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.47552	0.16609	-2.86	0.0064	12				
AR1,1	-0.17761	0.15496	-1.15	0.2578	2				
Variance Estimate			2.389E19						
Std Error Estimate			4.8875E9						
AIC			2232.471						
SBC			2236.171						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1							
MA1,1	1.000	-0.083							
AR1,1	-0.083	1.000							
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.86	4	0.0120	-0.494	-0.006	0.045	-0.045	0.044	-0.077
12	20.55	10	0.0245	0.213	-0.193	0.081	-0.106	-0.031	0.162
18	22.63	16	0.1241	0.012	-0.126	0.093	-0.057	0.023	-0.026
24	39.22	22	0.0133	0.083	-0.035	0.021	-0.021	-0.204	0.344
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.974139	Pr < W	0.3773					
Kolmogorov-Smirnov	D	0.112195	Pr > D	0.1421					
Cramer-von Mises	W-Sq	0.085844	Pr > W-Sq	0.1750					
Anderson-Darling	A-Sq	0.46834	Pr > A-Sq	0.2431					

Lampiran 39. Output SAS Pengujian Model ARIMA ([11],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.47858	0.19401	-2.47	0.0175	12				
AR1,1	-0.04059	0.21295	-0.19	0.8497	11				
Variance Estimate			2.456E19						
Std Error Estimate			4.9558E9						
AIC			2233.776						
SBC			2237.476						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1							
MA1,1	1.000	-0.495							
AR1,1	-0.495	1.000							
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	10.73	4	0.0297	-0.415	-0.161	0.095	0.015	-0.010	-0.069
12	17.42	10	0.0655	0.210	-0.147	0.039	-0.118	-0.003	0.170
18	19.43	16	0.2472	-0.001	-0.140	0.089	-0.020	-0.016	-0.018
24	36.58	22	0.0263	0.076	-0.008	0.029	-0.082	-0.175	0.361
Tests for Normality									
Test	--Statistic--			----p Value-----					
Shapiro-Wilk	W	0.98534	Pr < W	0.8142					
Kolmogorov-Smirnov	D	0.091514	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.035853	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.224882	Pr > A-Sq	>0.2500					

Lampiran 40. Output SAS Pengujian Model ARIMA (0,1,[1,12])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.49476		0.14557	3.40	0.0014	1			
MA1,2	-0.53324		0.18722	-2.85	0.0066	12			
Variance Estimate				1.703E19					
Std Error Estimate				4.1269E9					
AIC				2216.571					
SBC				2220.271					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	MA1,2							
MA1,1	1.000	0.078							
MA1,2	0.078	1.000							
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.24	4	0.1236	-0.225	-0.293	0.002	0.038	0.045	-0.045
12	16.27	10	0.0923	0.171	-0.128	-0.050	-0.135	0.002	0.278
18	19.20	16	0.2583	-0.073	-0.151	0.086	0.020	-0.047	-0.056
24	36.98	22	0.0238	0.131	0.047	-0.000	-0.157	-0.120	0.353
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.967709	Pr < W	0.2163					
Kolmogorov-Smirnov	D	0.110496	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.076015	Pr > W-Sq	0.2334					
Anderson-Darling	A-Sq	0.457332	Pr > A-Sq	>0.2500					
Forecasts for variable y									
Obs	Forecast	Std Error	95% Confidence Limits						
49	22416674789	4.12689E9	14328126045	30505223532					
50	19004681530	4.62371E9	9942368220	28066994839					
51	19391602393	5.07211E9	9450454357	29332750429					
52	19433717206	5.48396E9	8685353330	30182081082					
53	18349734801	5.86697E9	6850681459	29848788143					
54	18351357520	6.22647E9	6147705218	30555009822					
55	23418481303	6.56631E9	10548748157	36288214449					
56	19778784113	6.88941E9	6275786927	33281781299					
57	16673498477	7.19802E9	2565634190	30781362764					
58	18529040013	7.49394E9	3841196860	33216883166					
59	17232210064	7.7786E9	1986435625	32477984502					
60	21339604574	8.05321E9	5555608249	37123600899					

Lampiran 41. Output SAS Pengujian Model ARIMA ([1,2,11],1,0)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.61329	0.13416	-4.57	<.0001	1				
AR1,2	-0.47533	0.13447	-3.53	0.0010	2				
AR1,3	-0.42061	0.15199	-2.77	0.0082	11				
Variance Estimate			1.994E19						
Std Error Estimate			4.465E9						
AIC			2224.917						
SBC			2230.468						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	AR1,1	AR1,2	AR1,3						
AR1,1	1.000	0.366	0.133						
AR1,2	0.366	1.000	0.074						
AR1,3	0.133	0.074	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.41	3	0.0243	0.023	-0.179	-0.349	-0.027	0.151	0.032
12	33.37	9	0.0001	0.215	-0.140	-0.238	-0.239	0.207	0.398
18	36.81	15	0.0013	0.123	-0.133	-0.114	-0.037	0.041	0.009
24	60.27	21	<.0001	0.165	0.004	-0.192	-0.209	0.061	0.369
Tests for Normality									
Test		--Statistic--		----p Value-----					
Shapiro-Wilk		W	0.950841	Pr < W		0.0467			
Kolmogorov-Smirnov		D	0.134805	Pr > D		0.0314			
Cramer-von Mises		W-Sq	0.098037	Pr > W-Sq		0.1189			
Anderson-Darling		A-Sq	0.637643	Pr > A-Sq		0.0928			

Lampiran 42. Output SAS Pengujian Model ARIMA (1,1,[1,12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.61525	0.37772	1.63	0.1105	1				
MA1,2	-0.42590	0.22150	-1.92	0.0610	12				
AR1,1	0.33991	0.37507	0.91	0.3697	1				
Variance Estimate			2.047E19						
Std Error Estimate			4.5241E9						
AIC			2226.153						
SBC			2231.703						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	MA1,2	AR1,1						
MA1,1	1.000	0.214	0.884						
MA1,2	0.214	1.000	0.183						
AR1,1	0.884	0.183	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.91	3	0.0305	-0.337	-0.222	0.073	0.000	0.033	-0.079
12	21.39	9	0.0110	0.196	-0.123	0.016	-0.133	-0.080	0.346
18	25.03	15	0.0495	-0.090	-0.165	0.103	0.015	-0.028	-0.068
24	40.42	21	0.0066	0.141	-0.008	0.020	-0.105	-0.146	0.326
Tests for Normality									
Test		--Statistic--		----p Value----					
Shapiro-Wilk		W	0.976513	Pr < W	0.4570				
Kolmogorov-Smirnov		D	0.123072	Pr > D	0.0745				
Cramer-von Mises		W-Sq	0.063293	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.378087	Pr > A-Sq	>0.2500				

Lampiran 43. Output SAS Pengujian Model ARIMA ([2],1,[1,12])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.51552		0.14687	3.51	0.0010	1			
MA1,2	-0.51446		0.18653	-2.76	0.0084	12			
AR1,1	-0.14473		0.15403	-0.94	0.3525	2			
Variance Estimate				1.611E19					
Std Error Estimate				4.0136E9					
AIC				2214.897					
SBC				2220.447					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1		MA1,2		AR1,1				
MA1,1	1.000		0.208		0.138				
MA1,2	0.208		1.000		0.031				
AR1,1	0.138		0.031		1.000				
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.73	3	0.1253	-0.268	-0.175	-0.021	-0.020	0.082	-0.049
12	15.43	9	0.0798	0.171	-0.163	-0.029	-0.128	-0.024	0.284
18	17.59	15	0.2846	-0.061	-0.135	0.074	-0.010	-0.015	-0.053
24	33.75	21	0.0385	0.132	0.018	-0.002	-0.114	-0.129	0.345
Tests for Normality									
Test	--Statistic--			----p Value-----					
Shapiro-Wilk	W	0.950975	Pr < W	0.0473					
Kolmogorov-Smirnov	D	0.133708	Pr > D	0.0346					
Cramer-von Mises	W-Sq	0.140146	Pr > W-Sq	0.0322					
Anderson-Darling	A-Sq	0.805071	Pr > A-Sq	0.0362					

Lampiran 44. Output SAS Pengujian Model ARIMA ([11],1,[1,12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.49552	0.14858	3.34	0.0017	1				
MA1,2	-0.53255	0.20025	-2.66	0.0109	12				
AR1,1	0.06342	0.20312	0.31	0.7563	11				
Variance Estimate			1.745E19						
Std Error Estimate			4.1773E9						
AIC			2218.656						
SBC			2224.206						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	MA1,2	AR1,1						
MA1,1	1.000	0.156	-0.131						
MA1,2	0.156	1.000	-0.313						
AR1,1	-0.131	-0.313	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.26	3	0.0640	-0.238	-0.283	0.017	0.024	0.051	-0.045
12	16.80	9	0.0520	0.167	-0.133	-0.040	-0.127	-0.027	0.295
18	19.80	15	0.1797	-0.086	-0.148	0.088	0.015	-0.043	-0.057
24	37.26	21	0.0157	0.138	0.032	0.009	-0.149	-0.125	0.350
Tests for Normality									
Test		--Statistic--		----p Value----					
Shapiro-Wilk		W	0.966112	Pr < W	0.1875				
Kolmogorov-Smirnov		D	0.11231	Pr > D	0.1412				
Cramer-von Mises		W-Sq	0.082638	Pr > W-Sq	0.1940				
Anderson-Darling		A-Sq	0.488075	Pr > A-Sq	0.2210				

Lampiran 45. Output SAS Pengujian Model ARIMA ([1,2],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.79871		0.13033	6.13	<.0001	1			
AR1,1	-0.08334		0.18449	-0.45	0.6537	1			
AR1,2	-0.26932		0.17866	-1.51	0.1389	2			
Variance Estimate				1.885E19					
Std Error Estimate				4.3417E9					
AIC				2222.284					
SBC				2227.834					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	0.522	0.469						
AR1,1	0.522	1.000	0.275						
AR1,2	0.469	0.275	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.54	3	0.6740	-0.016	-0.022	-0.037	-0.066	0.139	-0.049
12	26.94	9	0.0014	0.132	-0.123	-0.067	-0.093	0.073	0.583
18	27.93	15	0.0220	0.088	-0.039	0.029	-0.010	0.046	-0.040
24	45.51	21	0.0015	0.138	-0.067	-0.072	-0.076	0.028	0.381
Tests for Normality									
Test	--Statistic--			----p Value----					
Shapiro-Wilk	W	0.839129	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.188157	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.513757	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	2.924146	Pr > A-Sq	<0.0050					

Lampiran 46. Output SAS Pengujian Model ARIMA ([1,2],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	-0.56630		0.15892	-3.56	0.0009	12			
AR1,1	-0.65542		0.14103	-4.65	<.0001	1			
AR1,2	-0.44735		0.14108	-3.17	0.0028	2			
Variance Estimate				1.643E19					
Std Error Estimate				4.0539E9					
AIC				2215.838					
SBC				2221.388					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	0.169	0.092						
AR1,1	0.169	1.000	0.439						
AR1,2	0.092	0.439	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.42	3	0.0596	-0.134	-0.199	-0.251	0.030	0.144	-0.002
12	17.07	9	0.0476	0.160	-0.160	-0.116	-0.177	0.147	0.196
18	18.72	15	0.2268	0.060	-0.133	0.014	-0.044	-0.003	-0.015
24	41.06	21	0.0055	0.135	0.073	-0.129	-0.161	-0.061	0.402
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.944749	Pr < W	0.0271					
Kolmogorov-Smirnov	D	0.133312	Pr > D	0.0358					
Cramer-von Mises	W-Sq	0.141824	Pr > W-Sq	0.0303					
Anderson-Darling	A-Sq	0.847133	Pr > A-Sq	0.0274					

Lampiran 47. Output SAS Pengujian Model ARIMA ([1,11],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.86950	0.10143	8.57	<.0001	1				
AR1,1	-0.0032814	0.19190	-0.02	0.9864	1				
AR1,2	0.12320	0.19329	0.64	0.5272	11				
Variance Estimate			1.976E19						
Std Error Estimate			4.4451E9						
AIC			2224.496						
SBC			2230.046						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	0.521	0.185						
AR1,1	0.521	1.000	0.197						
AR1,2	0.185	0.197	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.73	3	0.4349	-0.073	-0.176	0.025	0.026	0.116	-0.038
12	29.15	9	0.0006	0.171	-0.042	-0.036	-0.168	0.018	0.588
18	31.09	15	0.0086	0.025	-0.135	0.054	0.060	0.012	-0.040
24	49.05	21	0.0005	0.183	-0.020	-0.055	-0.118	-0.002	0.369
Tests for Normality									
Test	--Statistic--			----p Value----					
Shapiro-Wilk	W	0.884943	Pr < W	0.0002					
Kolmogorov-Smirnov	D	0.168323	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.345515	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	2.042218	Pr > A-Sq	<0.0050					

Lampiran 48. Output SAS Pengujian Model ARIMA ([1,11],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.52907	0.20650	-2.56	0.0139	12				
AR1,1	-0.46235	0.14099	-3.28	0.0020	1				
AR1,2	-0.03939	0.20412	-0.19	0.8478	11				
Variance Estimate			2.02E19						
Std Error Estimate			4.4942E9						
AIC			2225.53						
SBC			2231.08						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	0.102	-0.572						
AR1,1	0.102	1.000	0.002						
AR1,2	-0.572	0.002	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.18	3	0.0108	-0.186	-0.413	0.039	0.102	-0.023	-0.031
12	18.33	9	0.0315	0.188	-0.089	-0.103	-0.128	0.082	0.197
18	20.06	15	0.1697	-0.009	-0.134	0.046	0.018	-0.061	-0.003
24	41.65	21	0.0047	0.091	0.055	-0.011	-0.212	-0.081	0.398
Tests for Normality									
Test	--Statistic--			----p Value-----					
Shapiro-Wilk	W	0.983825	Pr < W	0.7531					
Kolmogorov-Smirnov	D	0.073789	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.035409	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.227533	Pr > A-Sq	>0.2500					

Lampiran 49. Output SAS Pengujian Model ARIMA ([2,11],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.82323		0.10525	7.82	<.0001	1			
AR1,1	-0.24601		0.17296	-1.42	0.1620	2			
AR1,2	0.04244		0.18692	0.23	0.8214	11			
Variance Estimate				1.893E19					
Std Error Estimate				4.3511E9					
AIC				2222.488					
SBC				2228.038					
Number of Residuals				47					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	0.380	0.030						
AR1,1	0.380	1.000	0.120						
AR1,2	0.030	0.120	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.91	3	0.5909	-0.083	-0.015	0.007	-0.062	0.147	-0.053
12	26.27	9	0.0018	0.148	-0.118	-0.028	-0.082	0.021	0.575
18	27.15	15	0.0275	0.053	-0.045	0.050	-0.002	0.052	-0.044
24	43.45	21	0.0028	0.148	-0.067	-0.044	-0.064	-0.002	0.368
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.82879	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.197625	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.546207	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	3.114252	Pr > A-Sq	<0.0050					

Lampiran 50. Output SAS Pengujian Model ARIMA ([2,11],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.45150	0.19546	-2.31	0.0256	12				
AR1,1	-0.18208	0.15681	-1.16	0.2518	2				
AR1,2	-0.06441	0.21280	-0.30	0.7636	11				
Variance Estimate			2.438E19						
Std Error Estimate			4.938E9						
AIC			2234.381						
SBC			2239.931						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2						
MA1,1	1.000	-0.094	-0.498						
AR1,1	-0.094	1.000	0.055						
AR1,2	-0.498	0.055	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.32	3	0.0064	-0.486	-0.007	0.030	-0.032	0.038	-0.078
12	20.04	9	0.0177	0.218	-0.190	0.078	-0.121	-0.009	0.154
18	22.27	15	0.1008	0.022	-0.136	0.094	-0.051	0.019	-0.026
24	38.65	21	0.0108	0.081	-0.025	0.011	-0.023	-0.200	0.344
Tests for Normality									
Test	--Statistic--		----p Value----						
Shapiro-Wilk	W	0.972624	Pr < W	0.3322					
Kolmogorov-Smirnov	D	0.095691	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.087116	Pr > W-Sq	0.1674					
Anderson-Darling	A-Sq	0.489681	Pr > A-Sq	0.2192					

Lampiran 51. Output SAS Pengujian Model ARIMA ([1,2,11],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.79915	0.13203	6.05	<.0001	1				
AR1,1	-0.08285	0.18984	-0.44	0.6647	1				
AR1,2	-0.26891	0.18291	-1.47	0.1488	2				
AR1,3	0.0020088	0.19206	0.01	0.9917	11				
Variance Estimate			1.929E19						
Std Error Estimate			4.3919E9						
AIC			2224.283						
SBC			2231.684						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2	AR1,3					
MA1,1	1.000	0.525	0.473	0.075					
AR1,1	0.525	1.000	0.295	0.185					
AR1,2	0.473	0.295	1.000	0.155					
AR1,3	0.075	0.185	0.155	1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.54	2	0.4634	-0.017	-0.022	-0.036	-0.066	0.139	-0.049
12	26.94	8	0.0007	0.133	-0.123	-0.067	-0.093	0.072	0.583
18	27.93	14	0.0145	0.088	-0.039	0.029	-0.010	0.046	-0.040
24	45.48	20	0.0009	0.139	-0.067	-0.072	-0.076	0.028	0.381
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.839057	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.190067	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.513607	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	2.924449	Pr > A-Sq	<0.0050					

Lampiran 52. Output SAS Pengujian Model ARIMA ([1,2,11],1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.52580	0.21515	-2.44	0.0187	12				
AR1,1	-0.65208	0.14276	-4.57	<.0001	1				
AR1,2	-0.44902	0.14300	-3.14	0.0031	2				
AR1,3	-0.06186	0.20168	-0.31	0.7605	11				
Variance Estimate			1.679E19						
Std Error Estimate			4.0978E9						
AIC			2217.768						
SBC			2225.169						
Number of Residuals			47						
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1	AR1,2	AR1,3					
MA1,1	1.000	0.136	0.081	-0.652					
AR1,1	0.136	1.000	0.432	-0.025					
AR1,2	0.081	0.432	1.000	-0.022					
AR1,3	-0.652	-0.025	-0.022	1.000					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.50	2	0.0235	-0.127	-0.192	-0.266	0.032	0.139	0.004
12	17.66	8	0.0239	0.165	-0.165	-0.123	-0.180	0.169	0.183
18	19.44	14	0.1489	0.075	-0.133	0.010	-0.046	-0.002	-0.011
24	41.89	20	0.0029	0.128	0.079	-0.136	-0.163	-0.059	0.402
Tests for Normality									
Test	--Statistic--		----p Value----						
Shapiro-Wilk	W	0.945353	Pr < W	0.0286					
Kolmogorov-Smirnov	D	0.137497	Pr > D	0.0244					
Cramer-von Mises	W-Sq	0.141365	Pr > W-Sq	0.0308					
Anderson-Darling	A-Sq	0.849752	Pr > A-Sq	0.0268					

Lampiran 53. Perhitungan Manual RMSE dan MAPE**Model ARIMA (0,1,[12])**

t	Z_t	\hat{Z}_t	$Z_t - \hat{Z}_t$	$(Z_t - \hat{Z}_t)^2$
49	14463985218	17419082968	-2955097750	8,7326E+18
50	14456980630	17419082968	-2962102338	8,77405E+18
51	12737120307	17419082968	-4681962661	2,19208E+19
52	15994479897	17419082968	-1424603071	2,02949E+18
53	14652200600	17419082968	-2766882368	7,65564E+18
54	19819880655	17419082968	2400797687	5,76383E+18
55	20939533205	17419082968	3520450237	1,23936E+19
56	12094643213	17419082968	-5324439755	2,83497E+19
57	12079563911	17419082968	-5339519057	2,85105E+19
58	17409929381	17419082968	-9153587	8,37882E+13
59	13337622815	17419082968	-4081460153	1,66583E+19
60	27259947795	17419082968	9840864827	9,68426E+19
Total = $\sum_{t=1}^n Z_t - \hat{Z}_t ^2$				2,37631E+20
$MSE = \frac{\sum_{t=1}^n Z_t - \hat{Z}_t ^2}{n}$				1,98026E+19
$RMSE = \sqrt{\frac{\sum_{t=1}^n Z_t - \hat{Z}_t ^2}{n}}$				4450010323

Lampiran 53. Perhitungan Manual RMSE dan MAPE**Model ARIMA (0,1,[12]) (Lanjutan)**

t	Z_t	\hat{Z}_t	$ Z_t - \hat{Z}_t $	$\frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$
49	14463985218	17419082968	2955097750	0,204307299
50	14456980630	17419082968	2962102338	0,204890801
51	12737120307	17419082968	4681962661	0,367584081
52	15994479897	17419082968	1424603071	0,089068421
53	14652200600	17419082968	2766882368	0,188837325
54	19819880655	17419082968	2400797687	0,121130784
55	20939533205	17419082968	3520450237	0,168124581
56	12094643213	17419082968	5324439755	0,440231238
57	12079563911	17419082968	5339519057	0,442029124
58	17409929381	17419082968	9153587	0,000525768
59	13337622815	17419082968	4081460153	0,306011064
60	27259947795	17419082968	9840864827	0,361000868
Total $\sum_{t=1}^n \frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$				2,893741355
$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$				0,241145113

Lampiran 54. Perhitungan Manual RMSE dan MAPE

Model ARIMA (0,1,[1,12])

t	Z_t	\hat{Z}_t	$Z_t - \hat{Z}_t$	$(Z_t - \hat{Z}_t)^2$
49	14463985218	22416674789	-7,953E+09	6,3245E+19
50	14456980630	19004681530	-4,548E+09	2,0682E+19
51	12737120307	19391602393	-6,654E+09	4,4282E+19
52	15994479897	19433717206	-3,439E+09	1,1828E+19
53	14652200600	18349734801	-3,698E+09	1,3672E+19
54	19819880655	18351357520	1468523135	2,1566E+18
55	20939533205	23418481303	-2,479E+09	6,1452E+18
56	12094643213	19778784113	-7,684E+09	5,9046E+19
57	12079563911	16673498477	-4,594E+09	2,1104E+19
58	17409929381	18529040013	-1,119E+09	1,2524E+18
59	13337622815	17232210064	-3,895E+09	1,5168E+19
60	27259947795	21339604574	5920343221	3,505E+19
Total = $\sum_{t=1}^n Z_t - \hat{Z}_t ^2$				2,93632E+20
$MSE = \frac{\sum_{t=1}^n Z_t - \hat{Z}_t ^2}{n}$				2,44693E+19
$RMSE = \sqrt{\frac{\sum_{t=1}^n Z_t - \hat{Z}_t ^2}{n}}$				4946646857

Lampiran 54. Perhitungan Manual RMSE dan MAPE**Model ARIMA (0,1,[1,12]) (Lanjutan)**

t	Z_t	\hat{Z}_t	$ Z_t - \hat{Z}_t $	$\frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$
49	14463985218	22416674789	7,95E+09	0,549827
50	14456980630	19004681530	4,55E+09	0,314568
51	12737120307	19391602393	6,65E+09	0,522448
52	15994479897	19433717206	3,44E+09	0,215027
53	14652200600	18349734801	3,7E+09	0,252354
54	19819880655	18351357520	1,47E+09	0,074093
55	20939533205	23418481303	2,48E+09	0,118386
56	12094643213	19778784113	7,68E+09	0,635334
57	12079563911	16673498477	4,59E+09	0,380306
58	17409929381	18529040013	1,12E+09	0,06428
59	13337622815	17232210064	3,89E+09	0,292
60	27259947795	21339604574	5,92E+09	0,217181
Total $\sum_{t=1}^n \frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$				3,635804
$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{ Z_t - \hat{Z}_t }{Z_t} \times 100\%$				0,302984

Lampiran 55. Syntax SAS Model ARIMA (0,1,[12]) untuk Peramalan

```

data penerimaan;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
12094643213
12079563911
17409929381
13337622815
27259947795
;
proc arima data=penerimaan out=out1;
identify var=y(1);
run;
estimate p=(0) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;

```

Lampiran 56. Output SAS Peramalan dengan Model ARIMA (0,1,[12])

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.56290	0.12219	-4.61	<.0001	12
Forecasts for variable y					
Obs	Forecast	Std Error	95% Confidence Limits		
61	22032855506	4.85297E9	12521203774	31544507239	
62	23761891288	6.86314E9	10310384408	37213398168	
63	21882524680	8.4056E9	5407860616	38357188744	
64	23593683579	9.70595E9	4570380114	42616987043	
65	23229404253	1.0852E10	1960704401	44498104104	
66	25858879362	1.1887E10	2560186007	49157572717	
67	23560220647	1.284E10	-1605244395	48725685688	
68	22184482376	1.3726E10	-4718531384	49087496137	
69	22214983737	1.4559E10	-6319971460	50749938934	
70	23334630839	1.5346E10	-6743852945	53413114623	
71	22530771953	1.6095E10	-9015807979	54077351886	
72	27707378161	1.6811E10	-5241949968	60656706289	

Obs	y	FORECAST	STD	L95	U95	RESIDUAL
1	10457671125					
2	6986366081	10457671125.0	4852972711.4	946019392.74	19969322857	-3471305044.00
3	8879130404	6986366081.0	4852972711.4	-2525285651.26	16498017813	1892764323.00
4	9958241751	8879130404.0	4852972711.4	-632521328.26	18390782136	1079111347.00
5	8633575373	9958241751.0	4852972711.4	446590018.74	19469893483	-1324666378.00
6	12573095215	8633575373.0	4852972711.4	-878076359.26	18145227105	3939519842.00
7	9217094399	12573095215.0	4852972711.4	3061443482.74	22084746947	-3356000816.00
8	16062967963	9217094399.0	4852972711.4	-294557333.26	18728746131	6845873564.00
9	10738458875	16062967963.0	4852972711.4	6551316230.74	25574619695	-5324509088.00
10	9195280340	10738458875.0	4852972711.4	1226807142.74	20250110607	-1543178535.00
11	10686511340	9195280340.0	4852972711.4	-316371392.26	18706932072	1491231000.00
12	21201043113	10686511340.0	4852972711.4	1174859607.74	20198163072	10514531773.00
13	11067561827	21201043113.0	4852972711.4	11689391380.74	30712694845	-10133481286.00
14	6846229020	9113576335.3	4852972711.4	-398075396.99	18625228068	-2267347315.28
15	7973456803	7911659450.2	4852972711.4	-1599992282.06	17423311182	61797352.80
16	9901054227	8580884813.3	4852972711.4	-930766918.97	18092536546	1320169413.71
17	10593028182	9155404146.9	4852972711.4	-356247585.33	18667055879	1437624035.06
18	11194638401	12810570149.1	4852972711.4	3298918416.82	22322212881	-1615931748.09
19	15757140640	9305557256.7	4852972711.4	-206094475.55	18817208989	6451583383.28
20	10071054097	19610658971.8	4852972711.4	10099007239.51	29122310704	-9539604874.77
21	11757565097	7073906518.0	4852972711.4	-2437745214.24	16585558250	4683658578.97
22	12626507253	10888915286.5	4852972711.4	1377263554.27	20400567019	1737591966.46
23	11540930140	13465915977.3	4852972711.4	3954264245.08	22977567710	-1924985837.35
24	21203218842	17459523371.2	4852972711.4	7947871638.90	26971175103	3743695470.84
25	13854394653	15499117599.8	4852972711.4	5987465867.54	25010769332	-1644722946.81
26	7718064571	12578112764.0	4852972711.4	3066461031.17	22089764496	-4860048193.03
27	11355209809	7752850085.2	4852972711.4	-1758801647.10	17264501817	3602359723.83
28	13701134749	12098328563.6	4852972711.4	2586676831.30	21609980296	1602806185.44
29	13489707650	14510368299.9	4852972711.4	4998716567.65	24022020032	-1020660649.92
30	10681046882	12580105309.9	4852972711.4	3068453577.59	22091757042	-1899058427.86
31	19325252655	14312620647.4	4852972711.4	4800968915.16	23824272380	5012632007.57
32	16180374082	13955442371.6	4852972711.4	4443790639.33	23467094104	2224931710.40
33	13610582031	18816789146.5	4852972711.4	9305137414.24	28328440879	-5206207115.51
34	15379088179	14588664683.4	4852972711.4	5077014751.12	24100318216	790421695.62
35	14312312499	14295520370.8	4852972711.4	4783868638.58	23807172103	16792128.15

Lampiran 56. Output SAS Peramalan dengan Model ARIMA (0,1,[12]) (Lanjutan)

Obs	y	FORECAST	STD	L95	U95	RESIDUAL
36	24522456422	16419625611.1	4852972711.4	6907973878.87	25931277343	8102830810.86
37	17595252608	23596647616.6	4852972711.4	14084995884.33	33108299349	-6001395008.60
38	9390193624	14859548445.5	4852972711.4	5347896713.21	24371200178	-5469354821.48
39	14293935146	11417949337.5	4852972711.4	1906297605.25	20929601070	2875985808.48
40	15582440728	15196149152.7	4852972711.4	5684497420.48	24707800885	386291575.25
41	13773002175	15007914411.1	4852972711.4	5496262678.79	24519566143	-1234912236.06
42	13585808104	12704028815.1	4852972711.4	3192377082.88	22215680547	881779288.86
43	25651157836	16407401163.1	4852972711.4	6895749430.83	25919052895	9243756672.91
44	15532280465	26903564129.0	4852972711.4	17391912396.79	36415215861	-11371283664.05
45	12478672289	12601724653.4	4852972711.4	3090072921.11	22113376386	-123052364.38
46	18859473844	12923597902.3	4852972711.4	3411946170.02	22435249635	5935875941.72
47	14171382712	18868926074.3	4852972711.4	9357274342.05	28380577807	-4697543362.32
48	27128212237	18732437890.3	4852972711.4	9220786158.01	28244089623	8395774346.72
49	14463985218	23750047936.2	4852972711.4	14238396203.91	33261699668	-9286062718.18
50	14456980630	11385304481.3	4852972711.4	1873652749.01	20896956214	3071676148.72
51	12737120307	16075863002.2	4852972711.4	6564211269.91	25587514734	-3338742695.18
52	15994479897	12954562486.3	4852972711.4	3442910753.99	22466214219	3039917410.75
53	14652200600	15299352110	4852972711.4	5787700377.9	24811003842	-647151510.12
54	19819880655	15148551084	4852972711.4	5636899351.3	24660202816	4671329571.40
55	20939533205	25023159018	4852972711.4	15511507286.0	34534810751	-4083625813.31
56	12094643213	14538677325	4852972711.4	5027025592.8	24050329057	-2444034112.09
57	12079563911	12025377467	4852972711.4	2513725734.4	21537029199	54186444.36
58	17409929381	15420847758	4852972711.4	5909196025.5	24932499490	1989081623.21
59	13337622815	14765698620	4852972711.4	5254046888.2	24277350353	-1428075805.42
60	27259947795	18063574887	4852972711.4	8551923154.7	27575226619	9196372907.99

Lampiran 57. Syntax SAS Peramalan Target 2018

```
data penerimaan;
input y;
datalines;
10457671125
6986366081
8879130404
9958241751
8633575373
12573095215
9217094399
16062967963
10738458875
9195280340
.
.
.
22184482376
22214983737
23334630839
22530771953
27707378161
;
proc arima data=penerimaan out=out1;
identify var=y(1);
run;
estimate p=(0) q=(12)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast lead=12 out=out2;
proc print data=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 58. *Output* SAS Peramalan Target 2018

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
73	27707236669	4.41746E9	19049170181	36365303158
74	27707379505	6.24723E9	15463024453	39951734557
75	27707268167	7.65127E9	12711057114	42703479221
76	27707366215	8.83492E9	10391233238	45023499192
77	27707345869	9.87775E9	8347320647	47067371091
78	27707476172	1.0821E10	6499631116	48915321228
79	27707195003	1.1688E10	4800104240	50614285766
80	27707410772	1.2494E10	3218700668	52196120876
81	27707322148	1.3252E10	1733122682	53681521613
82	27707274207	1.3969E10	328063971	55086484444
83	27707326676	1.4651E10	-1008231277	56422884628
84	27707553968	1.5303E10	-2284868138	57699976075

Lampiran 59. Output SAS Model ARIMA Jika Di Transformasi

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-6.4757E-8	2.78078E-7	-0.23	0.8169	0
MA1,1	-0.41345	0	-Infy	<.0001	12
Constant Estimate			-6.48E-8		
Variance Estimate			2.18E-12		
Std Error Estimate			1.477E-6		
AIC			-1126.67		
SBC			-1122.97		
Number of Residuals			47		
* AIC and SBC do not include log determinant.					
Correlations of Parameter Estimates					
Parameter	MU	MA1,1			
MU	1.000	0.000			
MA1,1	0.000	0.000			

Lampiran 60. Surat Pemberiaan Ijin Penelitian



**KEMENTERIAN KEUANGAN REPUBLIK INDONESIA
DIREKTORAT JENDERAL PAJAK
KANTOR WILAYAH DJP JAWA TIMUR I**

JALAN JAGIR WORKKROWO NO. 164 SURABAYA
TELEPON (031) 6443440; FAKS (031) 6441157; SITUS www.pajak.go.id
LAYANAN INFORMASI DAN KELUHAN KRING PAJAK (521) 600200
EMAIL pusat.layanan.pajak@pajak.go.id

Nomor : S- /2 /WPJ.11/BD.05/2017 23 Januari 2017
Sifat : Biasa
Lampiran : 1 set
Hal : Pemberian Ijin Penelitian

Yth. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Kampus ITS Sukolilo
Surabaya

Sehubungan dengan surat dari Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember Nomor : 001690/IT2.VI.1.3/TU.00.09/2017 tanggal 11
Januari 2017 perihal Permohonan Ijin Penelitian yang telah kami setuju atas :

Nama / NPM : Pratiwi Penta Atrivi / 1314030009
Perguruan Tinggi : Fakultas Matematika dan Ilmu Pengetahuan Alam Institut Teknologi
Sepuluh Nopember
Judul Skripsi : Peramalan Jumlah Pelapor SPT Masa PPh Pasal 21 di Kantor
Pelayanan Pajak Surabaya dengan Metode ARIMA BOX - JENKINS

dengan ini Kantor Wilayah DJP Jawa Timur I memberikan izin dan membantu memberikan
kesempatan magang/penyebaran kuesioner/penelitian dan/atau riset pada Seluruh Kepala
Kantor Pelayanan Pajak, sepanjang bahan-bahan keterangan/data yang digunakan untuk
keperluan akademis yang tidak untuk dipublikasikan dan tidak menyangkut rahasia
jabatan/negara sebagaimana diatur dalam ketentuan Pasal 34 UU KUP, adapun kegiatan
tersebut dapat dilaksanakan pada 1 Februari 2017 sampai dengan 31 Maret 2017.

Selanjutnya setelah selesai melaksanakan riset/penelitiannya, agar kepada mahasiswa yang
bersangkutan diminta untuk memberikan satu *soft-copy* hasil riset/penelitian tersebut sebagai
bahan masukan bagi Direktorat Jenderal Pajak. *Soft-copy* dimaksud dapat dikirim melalui email
ke alamat sebagai berikut: perustakaan@pajak.go.id.

Demikian, agar dapat dipergunakan sebagaimana mestinya.

a.n. Kepala Kantor
Kepala Bidang Penyuluhan, Pelayanan
dan Hubungan Masyarakat



Solih HutaJulu
NIP 196904011995031002

Tembusan :
1. Direktur P2Humas

Lampiran 61. Surat Pernyataan Keaslian Data**SURAT PERNYATAAN**

Saya yang bertanda tangan dibawah ini, mahasiswa Departemen Statistika
Bisnis Fakultas Vokasi ITS :

Nama : Pratiwi Penta Atrivi

NRP : 1314030009

Menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data
sekunder yang diambil dari Penelitian/Buku/Tugas Akhir/Thesis/Publikasi *)
yaitu

Sumber : Hasil Perekaman SPT Di Kantor Pelayanan Pajak
Surabaya Gubeng berdasarkan ijin dari Kantor
Wilayah DJP JATIM 1


Keterangan : Data Jumlah Penerimaan Masa PPh Pasal 21 Bulan
Januari Tahun 2012 sampai Desember 2016

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan
data, maka saya siap menerima sanksi sesuai dengan peraturan yang berlaku.

Mengetahui,
Dosen Pembimbing Tugas Akhir,


(Dra. Lucia Aridinanti, MT)
NIP. 19610131 198701 2 001

Surabaya, 19 Juni 2017
Yang Membuat Pernyataan,


(Pratiwi Penta Atrivi)
NRP. 1314030009

Halaman ini sengaja dikosongkan

BIODATA PENULIS



Penulis bernama lengkap Pratiwi Penta Atrivi. Lahir di Surabaya tanggal 22 Desember 1995. Penulis merupakan anak terakhir dari empat bersaudara. Penulis bertempat tinggal di Jalan Bulak Bnateng Baru Gang Cempaka No.29 Surabaya. Penulis menyelesaikan pendidikan di TK Al Sari Surabaya tahun 2002, SDN Bulak Banteng 1/263 Surabaya tahun 2008, SMPN 15 Surabaya tahun 2011, SMAN 9 Surabaya tahun 2014. Setelah lulus SMA, penulis mengikuti seleksi penerimaan mahasiswa baru dan diterima di program Diploma III melalui jalur seleksi reguler dengan NRP 1314 030 009 pada tahun 2014. Selama masa perkuliahan penulis memiliki pengalaman kerja sebagai surveyor di PT Mitra Pinasthika Mulia (MPM). Selain itu, penulis aktif mengikuti organisasi Himpunan Mahasiswa Diploma Statistika ITS sebagai staff dan Sekretaris Departemen PSDM (Pengembangan Sumber Daya Mahasiswa). Selain berpengalaman dalam organisasi, penulis juga aktif dalam kepanitiaan diantaranya MAKRAB (Malam Keakraban) FMIPA ITS, OKKBK (Orientasi Keprofesian dan Kompetensi Berbasis Kurikulum), STATION (*Statistics Competition*), CERITA (Cerdas Bersama Statistika), LKMM TD, Pelepasan Wisuda Departemen Statistika Bisnis, ketua panitia PENTAKASI (Pengenalan HIMADATA-ITS, IKASTA-ITS dan IHMSI) dan lain-lain. Penulis juga pernah mengikuti berbagai pelatihan diantaranya adalah pelatihan Surveyor, LKMM Pra TD, LKMM TD dan masih banyak lagi. Pada akhir semester 4, penulis mendapatkan kesempatan Kerja Praktek di Kantor Pelayanan Pajak Surabaya Gubeng. Penulis dapat dihubungi melalui email pratiwi.pentaatrivi@gmail.com apabila pembaca memiliki kritik, saran maupun berdiskusi lebih lanjut mengenai tugas akhir ini.